

UNIVERSIDADE FEDERAL DO PARANÁ

FELIPE MARTINS MARQUES DA SILVA

**INTEGRAÇÃO DE DADOS DE IMAGENS ORBITAIS DE ALTA RESOLUÇÃO E
ALS PARA DETECÇÃO SEMI-AUTOMÁTICA DE EDIFICAÇÕES EM ÁREAS
URBANAS.**

CURITIBA

2011

FELIPE MARTINS MARQUES DA SILVA

**INTEGRAÇÃO DE DADOS DE IMAGENS ORBITAIS DE ALTA RESOLUÇÃO E
ALS PARA DETECÇÃO SEMI-AUTOMÁTICA DE EDIFICAÇÕES EM ÁREAS
URBANAS.**

Dissertação apresentada ao Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra, Universidade Federal do Paraná, como requisito parcial para obtenção do título de Mestre em Ciências Geodésicas.

Orientador: Prof. Dr. Hideo Araki

CURITIBA

2011

TERMO DE APROVAÇÃO

FELIPE MARTINS MARQUES DA SILVA

*"INTEGRAÇÃO DE DADOS DE IMAGENS ORBITAIS DE ALTA RESOLUÇÃO E
ALS PARA DETECÇÃO SEMI-AUTOMÁTICA DE EDIFICAÇÕES EM ÁREAS
URBANAS"*

Dissertação nº 249 aprovada como requisito parcial do grau de Mestre no Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra da Universidade Federal do Paraná, pela seguinte banca examinadora:

Orientador:



Prof. Dr. Hideo Araki
Departamento de Geomática, UFPR



Prof. Dr. Álvaro Muriel Lima Machado
Departamento de Geomática, UFPR



Prof. Dr. Daniel Rodrigues dos Santos
Departamento de Geomática, UFPR

Curitiba, 26 de setembro de 2011.

DEDICATÓRIA

À minha família.

Aos meus pais, José Antônio e Maria do Carmo.

Ao meu irmão, Fernando.

A Diana, meu amor.

Por todo o incentivo e apoio, em todos os momentos.

AGRADECIMENTOS

A Deus, por tudo.

Ao professor Hideo Araki, meu orientador, pelos ensinamentos, incentivo, confiança, paciência e amizade.

Ao professor Jorge Centeno, pelas diversas orientações, apoio, confiança e amizade.

Aos professores Álvaro Muriel Lima Machado e Daniel Rodrigues dos Santos, membros da banca, tanto no Seminário I quanto na Defesa da Dissertação, que contribuíram para a melhora deste trabalho de pesquisa.

Aos demais professores, pelos ensinamentos.

Aos colegas Tiago Rodrigues, Marco Basso e Nadisson Pavan, pelo companheirismo, amizade e colaboração intelectual durante o curso.

Aos colegas André, Andrei, Eliziane, Fabiano, Hecrálito, Henry, Lineardo, Marli, Meire, Raul, Roberto, Rodrigo e Suzana, pela convivência.

Ao amigo Hélio Ademar Shuch, professor da UFSC, que me incentivou a busca pelo Mestrado.

Aos amigos Alecs Deszo e João Zottis, e seus familiares, por terem me recebido em Curitiba e pela convivência.

Ao LACTEC, a ENGESAT, e ao Prof. Alzir Fellipe Buffara Antunes por cederem os dados para esta pesquisa.

À SulSoft, por ter cedido uma licença temporária do software Envi Ex para a realização dos experimentos.

A CAPES, por conceder a bolsa de estudos.

A UFPR e ao Curso de Pós-Graduação em Ciências Geodésicas por me permitirem a oportunidade de cursar o Mestrado.

RESUMO

Atualmente, os sensores de alta resolução espacial e radiométrica disponíveis, conseguem adquirir imagens nas quais os objetos na superfície terrestre são representados por pixels submétricos. Aliado a isto, tem-se o LiDAR (*Light Detection And Ranging*), tecnologia de sensoriamento remoto ativo de varredura a *laser*, que é capaz de coletar coordenadas tridimensionais de milhares de pontos em um curto intervalo de tempo. A tecnologia LiDAR, quando acoplada a aeronaves, é conhecida por ALS (Airborne LiDAR System), e tem sido utilizada para realizar mapeamentos. A integração destas tecnologias – imagens orbitais de alta resolução e dados ALS – é desejada pelo fato de fornecerem dados tais que geram informações complementares. Diante disso, esta pesquisa apresenta uma metodologia para identificação de edificações em ambiente urbano, a partir de imagem de alta resolução GeoEye® e dados ALS, baseada em objetos e classificação com base em regras geradas por meio de árvores de decisão. A análise com base em objetos vem da possibilidade de segmentar a imagem, ou seja, dividi-la em regiões espectralmente homogêneas. Com os dados ALS foram gerados o Modelo Digital de Terreno (MDT), o Modelo Digital de Superfície (MDS), e o Modelo Digital de Superfície Normalizado (MDSn), da área de estudo. A partir do MDS e da imagem original obteve-se a imagem ortorretificada que, tendo o MDSn como banda adicional, foi segmentada pelo segmentador FLSA (*Full-Lambda Schedule Algorithm*). A partir de uma imagem menor, chamada imagem base, foram coletadas amostras de segmentos de classe, que foram utilizadas em uma árvore de decisão para gerar regras de identificação. Estas regras foram aplicadas em (extrapoladas para) uma imagem maior, chamada de imagem teste, de modo a identificar as demais edificações. Nesta pesquisa verifica-se a capacidade de integração dos dados, os atributos que mais contribuem para a identificação de edificações e a metodologia de extrapolação das regras de identificação.

ABSTRACT

Nowadays, the high spatial and radiometric resolutions sensors available are able to get images where objects on the surface are represented by submeter pixels. Along with those sensors, there is the LiDAR (Light Detection And Ranging), an active remote sensing technology able to collect three-dimensional coordinates of thousands of points in a short period of time. This technology, when embedded in aircrafts, is known as ALS (Airborne Laser Scanner), and it has been used to perform mappings. The integration of those technologies – high-resolution satellite images and ALS data – is desirable because they provide datasets such that are able to generate complementary information. Therefore, this research presents a methodology to identify buildings in an urban area using a GeoEye[®] image and ALS data, using an object-based analysis and rule-based classification generated by decision trees. The object-based analysis is possible after the image segmentation, that is, after dividing the image in spectrally homogeneous areas. With the ALS data it was created the Digital Terrain Model (DTM), the Digital Surface Model (DSM), and the Normalized Digital Surface Model (NDSM). By means of the DSM and the original image was made the orthorectified image. Adding the NDSM as a band of the orthorectified image, it was made the image segmentation. In a smaller image, called base image, it was collected samples of the segments in each class, then those samples were used in a decision tree to generate the identification rules. This rules were applied in (extrapolated to) a larger image, called test image, in order to classify another buildings. In this research it was verified the capability of data integration, the attributes that most contribute to identify buildings in urban areas, and the methodology of extrapolating the identification rules.

LISTA DE FIGURAS

| | |
|---|----|
| FIGURA 01 – SISTEMA ALS E SEUS COMPONENTES | 08 |
| FIGURA 02 – MOVIMENTOS <i>ROLL</i> , <i>PITCH</i> E <i>YAW</i> DA AERONAVE | 09 |
| FIGURA 03 – EXEMPLOS DE MÁSCARAS DE FILTROS | 26 |
| FIGURA 04 – EXEMPLO DE ÁRVORE DE DECISÃO; A HOMOGENEIDADE AUMENTA À MEDIDA QUE A ÁRVORE CRESCE | 31 |
| FIGURA 05 – DADOS ALS. VALORES E, N, h, I PARA CADA PONTO | 47 |
| FIGURA 06 – BASE VETORIZADA SOBRE A IMAGEM ÓPTICA. AS LEGENDAS MOSTRAM AS CLASSES DE EDIFICAÇÃO E RESPECTIVA QUANTIDADE DE EDIFICAÇÕES (OBJETOS) ENTRE PARÊNTESES | 48 |
| FIGURA 07 – BASE VETORIZADA. AS LEGENDAS MOSTRAM AS CLASSES DE EDIFICAÇÃO E A RESPECTIVA QUANTIDADE DE EDIFICAÇÕES (OBJETOS) ENTRE PARÊNTESES..... | 48 |
| FIGURA 08 – IMAGEM TESTE (MAIOR), IMAGEM BASE (MENOR), E RESPECTIVAS COORDENADAS DAS IMAGENS | 49 |
| FIGURA 09 – ETAPAS GERAIS DA METODOLOGIA | 51 |
| FIGURA 10 – DETALHAMENTO DAS ETAPAS DA METODOLOGIA | 52 |
| FIGURA 11 – DETALHAMENTO DA GERAÇÃO DO MDS, MDT E MDS _n | 53 |
| FIGURA 12 – PARTE DO MDS, RESOLUÇÃO 50 cm; NECESSITA INTERPOLAÇÃO E OP. MORFOLÓGICA DE FECHAMENTO | 54 |
| FIGURA 13 – PARTE DA IMAGEM INTENSIDADE, COM RESOLUÇÃO 50 cm, UTILIZADA PARA AUXILIAR A INTERPOLAÇÃO..... | 56 |
| FIGURA 14 – MATRIZ (3 x 3) E DIREÇÕES DE COMPARAÇÃO | 56 |
| FIGURA 15 – PARTE DO MDS INTERPOLADO ANALISANDO IM. DE ALTURA E DE INTENSIDADE. AINDA HÁ PIXEL SEM INFORMAÇÃO..... | 57 |
| FIGURA 16 – PARTE DO MDS APÓS OP. MORFOLÓGICA DE FECHAMENTO.. | 58 |
| FIGURA 17 – ELEMENTO ESTRUTURANTE DO FILTRO MORFOLÓGICO DE ABERTURA, 5 x 5, EM CRUZ..... | 58 |
| FIGURA 18 – MDS _n COM PIXELS DE REDE ELÉTRICA E MUROS (ESQUERDA) E MDS _n FILTRADO (DIREITA) | 59 |
| FIGURA 19 – DETALHAMENTO DA GERAÇÃO DA ORTOIMAGEM | 61 |
| FIGURA 20 – MAPEAMENTO INVERSO NA ORTORRETIFICAÇÃO; IMAGEM ORIGINAL, MDS E MATRIZ DA ORTORRETIFICAÇÃO POSSUEM A MESMA RESOLUÇÃO (GRADES IGUAIS) | 63 |
| FIGURA 21 – SEGMENTAÇÃO DA IMAGEM TESTE BASEIA-SE NA SEGMENTAÇÃO DA IMAGEM BASE, UTILIZADA NA GERAÇÃO DAS REGRAS. A IMAGEM TESTE, NA REGIÃO DA IMAGEM BASE, TEM SEGMENTOS IDÊNTICOS..... | 68 |
| FIGURA 22 – APLICAÇÃO DE REGRAS NA SEGMENTAÇÃO DA IMAGEM TESTE; | |

| | |
|--|----|
| SEGMENTOS IDENTIFICADOS DESTACADOS NA COR VERDE.. | 69 |
| FIGURA 23 – BASE VETORIZADA SOBREPOSTA AOS SEGMENTOS IDENTIFICADOS | 69 |
| FIGURA 24 – PIXELS NO MDS _n COM MDSN > 2,40M E NDVI < 0,62 | 72 |
| FIGURA 25 – IMAGEM RGB COM PIXELS COM MDSN > 2,40M E NDVI < 0,62.. | 72 |
| FIGURA 26 – PIXELS REMANESCENTES EM DIVERSAS FEIÇÕES | 73 |
| FIGURA 27 – ELEMENTO ESTRUTURANTE DO FILTRO MORFOLÓGICO DE FECHAMENTO, 5 x 5, EM CRUZ..... | 74 |
| FIGURA 28 – MELHORA DAS BORDAS DAS EDIFICAÇÕES | 74 |
| FIGURA 29 – PIXELS NO MDS _n COM MDSN > 2,40M E NDVI < 0,62, REMANESCENTES APÓS APLICAÇÃO DO FILTRO | 75 |
| FIGURA 30 – PIXELS NA IMAGEM OPTICA COM MDSN > 2,40M E NDVI < 0,62, REMANESCENTES APÓS APLICAÇÃO DO FILTRO | 75 |
| FIGURA 31 – SEGMENTAÇÃO FLISA NA IMAGEM COM MDSN > 2,40M E NDVI < 0,62 E FILTRADA COM FILTRO MORFOLÓGICO DE FECHAMENTO | 76 |
| FIGURA 32 – SEGMENTOS RESULTANTES DO EXPERIMENTO, COM A BASE VETORIZADA SUPERPOSTA | 77 |
| FIGURA 33 – MDS - MODELO DIGITAL DE SUPERFÍCIE | 78 |
| FIGURA 34 – MDS APÓS APLICAR FILTRO MORFOLÓGICO DE ABERTURA.... | 79 |
| FIGURA 35 – MDT - MODELO DIGITAL DE TERRENO | 80 |
| FIGURA 36 – MDS _n - MODELO DIGITAL SUPERFÍCIE NORMALIZADO | 81 |
| FIGURA 37 – DISTRIBUIÇÃO DOS PONTOS DE CONTROLE (PCs) E PONTOS DE VERIFICAÇÃO (PVs) NO ESPAÇO IMAGEM | 82 |
| FIGURA 38 – DISTRIBUIÇÃO DE PONTOS DE CONTROLE (PCs) E PONTOS DE VERIFICAÇÃO (PVs) NO ESPAÇO OBJETO | 83 |
| FIGURA 39 – IMAGEM ORTORRETIFICADA | 83 |
| FIGURA 40 – IMAGEM TESTE, MOSTRANDO A IMAGEM BASE INSERIDA NO POLÍGONO AMARELO | 86 |
| FIGURA 41 – IMAGEM BASE, UTILIZADA PARA GERAÇÃO DE REGRAS | 86 |
| FIGURA 42 – MDS _n DA IMAGEM BASE, UTILIZADA PARA GERAÇÃO DE REGRAS | 87 |
| FIGURA 43 – BANDAS MDS _n , R e IR _n CARREGADAS EM R, G, e B PARA A SEGMENTAÇÃO | 87 |
| FIGURA 44 – SEGMENTAÇÃO SOBRE IMAGEM RGB (SL=66 E ML=70) DA IMAGEM BASE | 88 |
| FIGURA 45 – SEGMENTAÇÃO SOBRE O MDS _n (SL=66 E ML=70) DA IMAGEM BASE .. | 88 |
| FIGURA 46 – SEGMENTAÇÃO SOBRE IMAGEM TESTE (SL=43 e ML=70) | 89 |
| FIGURA 47 – SEGMENTAÇÃO SOBRE MDS _n DA IM. TESTE (SL=43 e ML=70).. | 89 |
| FIGURA 48 – OCORRÊNCIAS DE DUPLO MAPEAMENTO | 90 |
| FIGURA 49 – SEGMENTAÇÃO EM ÁREA DE DUPLO MAPEAMENTO – RBG ... | 91 |
| FIGURA 50 – SEGMENTAÇÃO EM ÁREA DE DUPLO MAPEAMENTO – MDS _n ... | 91 |

| | |
|---|-----|
| FIGURA 51 – EXEMPLO DE ESCOLHA DE AMOSTRAS PARA EXPERIMENTOS DA SUBDIVISÃO X-A, SOBRE A IMAGEM ÓPTICA | 94 |
| FIGURA 52 – EXEMPLO DE ESCOLHA DE AMOSTRAS PARA EXPERIMENTOS DA SUBDIVISÃO X-A; LEGENDA COM OS NOMES DAS CLASSES E AS RESPECTIVAS QUANTIDADES DE AMOSTRAS | 94 |
| FIGURA 53 – EXEMPLO DE ESCOLHA DE AMOSTRAS PARA EXPERIMENTOS DA SUBDIVISÃO X-B; LEGENDA COM OS NOMES DAS CLASSES E AS RESPECTIVAS QUANTIDADES DE AMOSTRAS | 95 |
| FIGURA 54 – EXEMPLO DE ESCOLHA DE AMOSTRAS PARA EXPERIMENTOS DA SUBDIVISÃO X-C; LEGENDA COM OS NOMES DAS CLASSES E AS RESPECTIVAS QUANTIDADES DE AMOSTRAS | 95 |
| FIGURA 55 – EXEMPLO DE TABELA DAS REGRAS DOS EXPERIMENTOS | 96 |
| FIGURA 56 – EXEMPLO DE APLICAÇÃO DAS REGRAS..... | 97 |
| FIGURA 57 – EDIFICAÇÕES PARCIALMENTE DETECTADAS | 97 |
| FIGURA 58 – EXEMPLO DE TABELA DOS RESULTADOS DOS EXPERIMENTOS | 99 |
| FIGURA 59 – APLICAÇÃO DAS REGRAS 1 A 12, DO EXPERIMENTO 1-A | 104 |
| FIGURA 60 – APLICAÇÃO DAS REGRAS 1 A 9, DO EXPERIMENTO 1-B | 113 |
| FIGURA 61 – APLICAÇÃO DA REGRA ÚNICA DO EXPERIMENTO 1-C | 119 |
| FIGURA 62 – A DIVERSIDADE DE FORMAS POSSÍVEIS DE EDIFICAÇÕES E SEUS RESPECTIVOS SEGMENTOS, TENDEM A DIFICULTAR O GANHO DE INFORMAÇÃO PELO USO DE ATRIBUTOS DE FORMA | 148 |

LISTA DE TABELAS

| | |
|---|-----|
| TABELA 01 – RESULTADOS DO EXPERIMENTO 1-A | 110 |
| TABELA 02 – RESULTADOS DO EXPERIMENTO 1-B | 118 |
| TABELA 03 – RESULTADOS DO EXPERIMENTO 1-C | 120 |
| TABELA 04 – RESULTADOS DO EXPERIMENTO 2-A | 122 |
| TABELA 05 – RESULTADOS DO EXPERIMENTO 2-B | 124 |
| TABELA 06 – RESULTADOS DO EXPERIMENTO 2-C | 126 |
| TABELA 07 – RESULTADOS DO EXPERIMENTO 3-A | 128 |
| TABELA 08 – RESULTADOS DO EXPERIMENTO 3-B | 130 |
| TABELA 09 – RESULTADOS DO EXPERIMENTO 3-C | 131 |
| TABELA 10 – RESULTADOS DO EXPERIMENTO 4-A | 133 |
| TABELA 11 – RESULTADOS DO EXPERIMENTO 4-B | 136 |
| TABELA 12 – RESULTADOS DO EXPERIMENTO 4-C | 137 |
| TABELA 13 – RESULTADOS DO EXPERIMENTO 5-A | 139 |
| TABELA 14 – RESULTADOS DO EXPERIMENTO 5-B | 142 |
| TABELA 15 – RESULTADOS DO EXPERIMENTO 5-C | 143 |

LISTA DE QUADROS

| | |
|--|-----------|
| QUADRO 01 – FONTES DE ERROS EM IMAGENS DE SATÉLITE | 06 |
| QUADRO 02 – REQUISITOS BÁSICOS DA SEGMENTAÇÃO | 10 |
| QUADRO 03 – SENSORES DO SATÉLITE GEOEYE®1..... | 25 |
| QUADRO 04 – CARACTERÍSTICAS DA IMAGEM UTILIZADA NA PESQUISA | 45 |
| QUADRO 05 – CARACTERÍSTICAS DO EQUIPAMENTO LASERSCANNER | 46 |
| QUADRO 06 – CARACTERÍSTICAS DO VÔO | 46 |
| QUADRO 07 – EXPERIMENTOS REALIZADOS | 93 |
| QUADRO 08 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 1-A..... | 103 |
| QUADRO 09 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 1-B..... | 112 e 113 |
| QUADRO 10 – REGRA REFERENTE À EDIFICAÇÃO NO EXPERIMENTO 1-C | 119 |
| QUADRO 11 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 2-A | 121 |
| QUADRO 12 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 2-B | 124 |
| QUADRO 13 – REGRA REFERENTE À EDIFICAÇÃO NO EXPERIMENTO 2-C | 126 |
| QUADRO 14 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 3-A | 127 e 128 |
| QUADRO 15 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 3-B | 130 |
| QUADRO 16 – REGRA REFERENTE À EDIFICAÇÃO NO EXPERIMENTO 3-C. | 131 |
| QUADRO 17 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 4-A | 132 e 133 |
| QUADRO 18 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 4-B | 135 |
| QUADRO 19 – REGRA REFERENTE À EDIFICAÇÃO NO EXPERIMENTO 4-C | 137 |
| QUADRO 20 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 5-A..... | 138 e 139 |
| QUADRO 21 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 5-B..... | 141 |
| QUADRO 22 – REGRA REFERENTE À EDIFICAÇÃO NO EXPERIMENTO 5-C. | 143 |
| QUADRO 23 – GRÁFICOS REPRESENTATIVOS DOS INDICES DE ACURÁCIA POR CLASSE E GLOBAL NOS EXPERIMENTOS 1, 2 e 3..... | 145 |
| QUADRO 24 – GRÁFICOS REPRESENTATIVOS DOS INDICES DE ACURÁCIA POR CLASSE E GLOBAL NOS EXPERIMENTOS 4 e 5..... | 146 |

LISTA DE SIGLAS

AI – Accuracy Index
AG – Acurácia Global do experimento
ALDPAT – *Airborne LiDAR Data Processing and Analysis Tools*
ALS – Airborne Laser Scanning
CFS – Correlation-based Feature Selection
DEM – Digital Elevation Model
DLT – Direct Linear Transform
DN – Digital Number
ENVI – Environment for Visualizing Images
FCBF – Fast Correlation-Based Feature selection
FLSA – Full-Lambda Schedule Algorithm
FNEA – Fractal Net Evolution Approach
GIS – Geographic Information System
GPS – Global Position System
IFOV – Instantaneous Field of View
IMU – Inertial Measurement Unit
INS – Inertial Navigation System
ISODATA – Iterative Self-Organizing Data Analysis Technique
LACTEC – Instituto de Tecnologia para o Desenvolvimento
LaDAR – Laser Detection and Ranging
LASER – Light Amplification by Stimulated Emission of Radiation
LiDAR – Light Detection and Ranging
MATLAB – Matrix Laboratory
MDS – Modelo Digital de Superfície
MDS_n – Modelo Digital de Superfície normalizado
MDT – Modelo Digital de Terreno
ML – Merge Level
MMQ – Método dos Mínimos Quadrados
NDVI – Normalized Difference Vegetation Index

PCs – Pontos de Controle

PVs – Pontos de Verificação

RFM – Rational Function Model

RMSE – Root Mean Square Error ou Erro Médio Quadrático

RPC – Rational Polynomial Camera, Rational Polynomial Coefficients ou Rapid
Positioning Capability

SAR – Syntetic Aperture Radar

SIG – Sistema de Informações Geográficas

SL – Scale Level

SPOT – Système Pour l'Observation de la Terre

WEKA – Waikato Environment Knowledge Analysis

SUMÁRIO

| | |
|--|-----------|
| 1 INTRODUÇÃO | 01 |
| 1.1 ESTRUTURA DA DISSERTAÇÃO | 02 |
| 1.2 JUSTIFICATIVA | 03 |
| 1.3 HIPÓTESE | 04 |
| 1.4 OBJETIVO GERAL | 04 |
| 1.5 OBJETIVOS ESPECÍFICOS | 04 |
| 2 FUNDAMENTAÇÃO TEÓRICA | 05 |
| 2.1 IMAGENS DE ALTA RESOLUÇÃO ESPACIAL E RADIOMÉTRICA | 05 |
| 2.2 LASER SCANNER AEROTRANSPORTADO (ALS) | 07 |
| 2.3 ORTORRETIFICAÇÃO DE IMAGENS DIGITAIS | 10 |
| 2.3.1. Modelos Matemáticos Físicos | 11 |
| 2.3.2. Modelos Matemáticos Generalizados | 11 |
| 2.3.2.1. Transformação Projetiva | 13 |
| 2.4 CLASSIFICAÇÃO DE IMAGENS DIGITAIS | 15 |
| 2.4.1 Classificação com base no pixel | 16 |
| 2.4.1.1 Classificação supervisionada | 16 |
| 2.4.1.2 Classificação não supervisionada | 17 |
| 2.4.2 Classificação com base no objeto | 17 |
| 2.4.2.1 Atributos espectrais | 18 |
| 2.4.2.2 Atributos de forma | 19 |
| 2.4.2.3 Atributos de textura | 22 |
| 2.4.2.4 Classificação utilizando apenas atributos espectrais | 23 |
| 2.4.2.5 Classificação utilizando atributos espectrais, de forma e de textura | 24 |
| 2.5 SEGMENTAÇÃO DE IMAGENS DIGITAIS | 24 |
| 2.5.1 Segmentação por detecção de descontinuidades | 26 |
| 2.5.1.1 Detecção de bordas | 26 |
| 2.5.2 Segmentação por detecção de similaridades | 27 |
| 2.5.2.1 Crescimento de regiões (<i>region growing</i>) | 27 |
| 2.5.2.2 Divisão e fusão (<i>splitting and merging</i>) | 28 |
| 2.5.3. <i>Fractal Net Evolution Approach</i> – FNEA | 28 |
| 2.5.4 <i>Full-Lambda Schedule Algorithm</i> – FLSA | 28 |
| 2.6 ÁRVORES DE DECISÃO | 30 |
| 2.6.1 Elementos e objetivos de uma árvore de decisão | 32 |
| 2.6.2 Construção da árvore de decisão | 33 |
| 2.6.3 Testes candidatos e teste selecionado | 34 |
| 2.6.3.1 Entropia ou Informação potencial | 34 |
| 2.6.3.2 Ganho de informação | 35 |
| 2.6.3.3 Razão de ganho | 36 |
| 2.6.4 Superadaptação (<i>overfitting</i>) | 36 |
| 2.6.5 Poda (<i>pruning</i>) | 37 |
| 3 ESTADO DA ARTE..... | 38 |
| 3.1 ESTADO DA ARTE DA SEGMENTAÇÃO DE IMAGENS E DADOS ALS | 38 |

| | |
|---|-----------|
| 3.2 ESTADO DA ARTE DAS ÁRVORES DE DECISÃO..... | 42 |
| 3.3 CONSIDERAÇÕES SOBRE O ESTADO DA ARTE | 43 |
| 4. DADOS, ÁREA DE ESTUDO E RECURSOS | 45 |
| 4.1 DADOS | 45 |
| 4.1.1 Imagem de alta resolução – GeoEye | 45 |
| 4.1.2 Dados de Laser Scanner Aerotransportado – ALS | 46 |
| 4.1.3 Base Vetorizada | 47 |
| 4.2 ÁREA DE ESTUDO | 49 |
| 4.3 RECURSOS DE HARDWARE E SOFTWARE | 50 |
| 5 METODOLOGIA | 51 |
| 5.1 MODELOS DIGITAIS - MDS, MDT E MDSn | 52 |
| 5.1.1 MDS – Modelo Digital de Superfície..... | 53 |
| 5.1.1.1 Projeção dos pontos em uma grade | 54 |
| 5.1.1.2 Interpolação | 55 |
| 5.1.1.3 Filtro Morfológico de Fechamento | 57 |
| 5.1.1.4 Filtro Morfológico de Abertura | 58 |
| 5.1.2 MDT – Modelo Digital de Terreno | 59 |
| 5.1.3 MDSn – Modelo Digital de Superfície Normalizado | 60 |
| 5.2 ORTORRETIFICAÇÃO | 61 |
| 5.3 SEGMENTAÇÃO E REGRAS | 63 |
| 5.3.1 Segmentação FLSA da imagem Base | 64 |
| 5.3.2 Seleção de amostras para cada classe | 64 |
| 5.3.3 Árvore de Decisão – Algoritmo J48 no WEKA | 65 |
| 5.3.4 Definição das Regras | 67 |
| 5.4 IDENTIFICAÇÃO (Aplicação das regras) | 67 |
| 5.4.1 Segmentação FLSA da Imagem Teste | 67 |
| 5.4.2 Aplicação das Regras sobre a segmentação da Imagem Teste | 68 |
| 5.5. AVALIAÇÃO E QUANTIFICAÇÃO DOS RESULTADOS..... | 70 |
| 6 EXPERIMENTO PRÉVIO, COM BASE | |
| NO PIXEL, UTILIZANDO O CONHECIMENTO DO ANALISTA | 71 |
| 6.1 PIXELS COM MDSN > 2,40M E NDVI < 0,62..... | 71 |
| 6.2 ELIMINAÇÃO DE RUÍDOS E MELHORA DAS BORDAS NO MDSN EXTRAÍDO (FILTRO MORFOLÓGICO DE ABERTURA, 5 x 5, EM CRUZ)..... | 73 |
| 6.3 EXTRAÇÃO DOS PIXELS DAS BANDAS DO VISÍVEL SEGUNDO O MDSN MELHORADO..... | 74 |
| 6.4 SEGMENTAÇÃO FLSA..... | 76 |
| 6.5. RESULTADO DO EXPERIMENTO PRÉVIO | 76 |
| 6.5.1. Análise do Resultado | 77 |
| 7 RESULTADOS | 78 |
| 7.1 MDS – MODELO DIGITAL DE SUPERFÍCIE | 78 |
| 7.1.1. Filtro Morfológico de Abertura aplicado ao MDS | 78 |
| 7.2 MDT – MODELO DIGITAL DE TERRENO | 80 |
| 7.3 MDSn – MODELO DIGITAL DE SUPERFÍCIE NORMALIZADO | 81 |
| 7.4 ORTORRETIFICAÇÃO | 82 |
| 7.5 SEGMENTAÇÃO FLSA | 84 |
| 7.5.1 Áreas com Duplo Mapeamento | 90 |

| | |
|---|------------|
| 7.6 EXPERIMENTOS | 92 |
| 7.6.1 Experimentos 1 (Banda 1 = B) | 103 |
| 7.6.1.1 Experimento 1-A | 103 |
| 7.6.1.1.1 Análise dos resultados do Experimento 1-A..... | 110 |
| 7.6.1.2 Experimento 1-B | 112 |
| 7.6.1.2.1 Análise dos resultados do Experimento 1-B..... | 118 |
| 7.6.1.3 Experimento 1-C | 119 |
| 7.6.1.3.1 Análise dos resultados do Experimento 1-C..... | 120 |
| 7.6.2 Experimentos 2 (Banda 1 = G) | 120 |
| 7.6.2.1 Experimento 2-A..... | 121 |
| 7.6.2.1.1 Análise dos resultados do Experimento 2-A..... | 122 |
| 7.6.2.2 Experimento 2-B..... | 124 |
| 7.6.2.2.1 Análise dos resultados do Experimento 2-B..... | 125 |
| 7.6.2.3 Experimento 2-C..... | 126 |
| 7.6.2.3.1 Análise dos resultados do Experimento 2-C..... | 126 |
| 7.6.3 Experimentos 3 (Banda 1 = R) | 127 |
| 7.6.3.1 Experimento 3-A..... | 127 |
| 7.6.3.1.1 Análise dos resultados do Experimento 3-A..... | 128 |
| 7.6.3.2 Experimento 3-B..... | 129 |
| 7.6.3.2.1 Análise dos resultados do Experimento 3-B..... | 130 |
| 7.6.3.3 Experimento 3-C..... | 131 |
| 7.6.3.3.1 Análise dos resultados do Experimento 3-C..... | 132 |
| 7.6.4 Experimentos 4 (Banda 1 = IRn) | 132 |
| 7.6.4.1 Experimento 4-A..... | 132 |
| 7.6.4.1.1 Análise dos resultados do Experimento 4-A..... | 134 |
| 7.6.4.2 Experimento 4-B..... | 135 |
| 7.6.4.2.1 Análise dos resultados do Experimento 4-B..... | 136 |
| 7.6.4.3 Experimento 4-C | 137 |
| 7.6.4.3.1 Análise dos resultados do Experimento 4-C..... | 137 |
| 7.6.5 Experimentos 5 (Banda 1 = MDSn) | 138 |
| 7.6.5.1 Experimento 5-A..... | 138 |
| 7.6.5.1.1 Análise dos resultados do Experimento 5-A..... | 140 |
| 7.6.5.2 Experimento 5-B..... | 141 |
| 7.6.5.2.1 Análise dos resultados do Experimento 5-B..... | 142 |
| 7.6.5.3 Experimento 5-C | 143 |
| 7.6.5.3.1 Análise dos resultados do Experimento 5-C..... | 143 |
| 7.7. VISÃO GERAL DOS ÍNDICES DE ACURÁCIA DOS EXPERIMENTOS | 145 |
| 7.8. SÍNTESE DOS RESULTADOS | 147 |
| 8 CONCLUSÕES | 149 |
| 9 RECOMENDAÇÕES | 152 |
| 10 REFERÊNCIAS BIBLIOGRÁFICAS | 153 |
| APÊNDICE A – RELATÓRIO DO PROGRAMA DA ORTORRETIFICAÇÃO | 161 |
| APÊNDICE B – ÁRVORES DE DECISÃO DOS EXPERIMENTOS 1, 2, 3, 4 E 5.. | 164 |

1. INTRODUÇÃO

O planejamento urbano sustentável necessita de informações georreferenciadas atualizadas e confiáveis. Os sensores orbitais, imageadores e passivos, de sensoriamento remoto de alta resolução espacial se apresentam como uma fonte de informações deste tipo. Estes sensores têm evoluído de tal forma que a gama de aplicações das imagens geradas vem crescendo junto com a capacidade de detalhamento das imagens. No atual estado da arte, as imagens de alta resolução captam imagens cujo pixel representa uma área menor que 1 m² no terreno. Juntamente com as imagens de alta resolução, outra tecnologia disponível é o Laser Scanner Aerotransportado ou, em inglês, *Airborne Laser Scanning* (ALS). Trata-se de um sensor ativo que permite adquirir uma alta densidade pontos cujas coordenadas tridimensionais permitem gerar o Modelo Digital de Superfície.

O aumento da resolução espacial dos sensores, ao mesmo tempo em que aumenta sua aplicabilidade, traz consigo a necessidade de desenvolver metodologias capazes de aproveitar todo este potencial de maneira ágil e confiável. As tecnologias de sensoriamento remoto permitem gerar grandes quantidades de imagens de alta resolução, mas que só serão realmente aproveitadas se, a partir destas, possam ser obtidas informações úteis. É neste contexto que a automação dos métodos de identificação de edificações em ambiente urbano se faz importante, buscando obter informações confiáveis a partir de imagens de alta resolução espacial e espectral de áreas urbanas.

Tentativas de identificação de edificações tem sido realizadas seguindo basicamente duas abordagens: abordagem com base no pixel, ou abordagem com base no objeto. A abordagem com base no pixel se utiliza apenas da informação espectral de cada pixel, buscando classificá-lo de acordo com amostras previamente fornecidas (classificação supervisionada) de pixels das classes de feições desejadas. Já abordagem com base no objeto consiste em se obter áreas homogêneas na imagem, utilizando-se de técnicas de segmentação da imagem, onde cada uma destas áreas é um objeto ou segmento, e que pode se classificado por atributos de forma, além do atributo espectral característico dos pixels inseridos no segmento. Atributo é a representação numérica de alguma característica do segmento, permitindo mensurá-lo e analisá-lo matematicamente. Em ambas as

abordagens a classificação pode ser feita utilizando métodos estatísticos paramétricos, como o método de verossimilhança, ou estatísticos não paramétricos, como as árvores de decisão.

Este trabalho apresenta uma metodologia para identificação de edificações em ambiente urbano, a partir de imagem de alta resolução GeoEye® e dados ALS, por meio de segmentação de imagens e classificação com base em regras. Em linhas gerais, a metodologia consiste em obter regras de identificação de edificações em uma imagem menor, seguido da extrapolação destas regras para identificar outras edificações em uma imagem maior. Para avaliar os resultados, a identificação obtida na imagem maior é comparada com uma vetorização manual das edificações da imagem, sendo essa vetorização tida como “verdade de campo”.

Espera-se que esta pesquisa contribua no desenvolvimento de metodologias capazes de obter informações rápidas e confiáveis a partir de dados obtidos pelo Sensoriamento Remoto.

1.1. ESTRUTURA DA DISSERTAÇÃO

Após a Introdução feita, o Capítulo 1 segue com a apresentação da justificativa, hipótese da pesquisa, o objetivo geral e os objetivos específicos.

O Capítulo 2 apresenta a fundamentação teórica que baseia esta pesquisa, abordando a caracterização dos dados utilizados – imagens de alta resolução e dados ALS –, bem como as técnicas de processamento dos dados empregadas – geração de modelos de superfície, ortorretificação, segmentação, e árvores de decisão. O Capítulo 3 trata do estado da arte, apresentando resumos de diversos trabalhos científicos que utilizaram dados ALS e imagens de sensores ópticos em áreas urbanas. O Capítulo 4 apresenta os dados utilizados na pesquisa e as características de *hardware* e *software* empregados.

A metodologia desenvolvida na pesquisa é apresentada no Capítulo 5, seguindo-se do Capítulo 6, onde é realizado um experimento baseado no pixel, utilizando o conhecimento do analista. No Capítulo 7 são apresentados os resultados obtidos em cada etapa e em cada experimento realizado, bem como suas análises. O Capítulo 8 apresenta as conclusões da pesquisa.

Recomendações e sugestões sobre trabalhos futuros são feitas no Capítulo 9 e, por fim, no Capítulo 10, apresentam-se as referências bibliográficas consultadas.

1.2. JUSTIFICATIVA

Atualmente há uma grande disponibilidade de dados de imagens de alta resolução - espacial e radiométrica - geradas a partir de plataformas orbitais desenvolvidas por órgãos públicos e privados em países como Brasil, Estados Unidos, Canadá, China, França, dentre outros. Diante disso, as comunidades acadêmicas de diversos países – mesmo dos que não possuem satélites próprios, nem públicos, nem privados – têm realizado estudos para o desenvolvimento de metodologias que extraíam automaticamente informações confiáveis a partir destas imagens.

Diversas metodologias foram desenvolvidas visando extrair informações de imagens para as mais diversas áreas do conhecimento. Dentre estas áreas, destaca-se a extração de informações em áreas urbanas, importantes para o planejamento urbano sustentável em municípios, seja de pequeno, médio ou grande porte. Informações sobre alterações da área urbana são fundamentais para permitir tomadas de decisão em políticas públicas de desenvolvimento. Uma das formas de se verificar a alteração da área urbana é pela alteração do número de edificações existentes. Um crescimento do número de edificações pode indicar eventos como: o aumento da população local; o crescimento desordenado do município; a construção de edificações não regularizadas ou em área irregular, como áreas de preservação; o avanço da área urbana em uma determinada direção, demandando investimentos de infra-estrutura tais como estradas, energia elétrica ou abastecimento de água, naquela direção; etc.

Assim, a identificação e quantificação de edificações a partir de imagens de satélite se apresenta como uma ferramenta de auxílio para a tomada de decisão em políticas públicas.

1.3. HIPÓTESE

A hipótese deste trabalho é: “A integração de dados de imagens de alta resolução e dados ALS, utilizando análise baseada no objeto e regras obtidas com árvores de decisão, permite identificar edificações em ambientes urbanos”

1.4. OBJETIVO GERAL

O objetivo geral desta pesquisa é *“desenvolver uma metodologia para identificação de edificações em ambiente urbano, utilizando imagem de alta resolução GeoEye® e dados ALS, por meio de segmentação de imagens e regras obtidas com árvores de decisão”*.

1.5. OBJETIVOS ESPECÍFICOS

São objetivos específicos:

- Integrar dados ALS e dados de Imagens de alta resolução para realizar análise baseada no objeto.
- Verificar quais os atributos que mais contribuem para identificar edificações em ambiente urbano.
- Avaliar a capacidade de generalização das regras geradas em uma árvore de decisão, a partir de amostras coletadas em uma imagem base (menor), aplicadas sobre uma imagem teste (maior).

2. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo é apresentada a fundamentação teórica relativa às imagens de alta resolução, *laser scanner* aerotransportado (ALS), ortorretificação, classificação e segmentação de imagens digitais e árvores de decisão.

2.1. IMAGENS DE ALTA RESOLUÇÃO ESPACIAL E RADIOMÉTRICA

A definição de resolução espacial, no sensoriamento remoto, é a área unitária representada por um pixel da imagem, onde quanto menor a área representada, maior a resolução espacial. Se uma imagem *A* representa uma área “*x*” com 20 pixels e outra imagem *B* representa esta mesma área “*x*” com 40 pixels, pode-se afirmar que a resolução espacial da imagem *B* é maior que a da imagem *A*. Segundo Jensen (2009), os sensores remotos de alta resolução espacial são aqueles cujo pixel corresponde no terreno a uma dimensão menor que 4m x 4m. A resolução radiométrica de imagens digitais, por sua vez, está associada à sensibilidade do sensor em distinguir diferentes níveis de energia eletromagnética captada, apresentando um maior número de tonalidades (níveis ou tons de cinza) na imagem.

Tendo-se uma alta resolução espacial e uma alta resolução radiométrica em uma imagem, é possível distinguir melhor objetos nela presentes. Caso uma destas características não ocorra, dificulta-se a distinção dos objetos. No caso de se ter uma alta resolução espacial com uma baixa resolução radiométrica, será difícil distinguir feições devido à incapacidade de representação de diferentes tonalidades dos materiais dos objetos. Já no caso de se ter uma alta resolução radiométrica com uma baixa resolução espacial, haverá maior quantidade de pixels mistos, que é quando mais de uma feição é representada em um mesmo pixel, incapacitando a distinção.

As imagens de alta resolução espacial e radiométrica trouxeram um grande incentivo à utilização de imagens orbitais para mapeamentos. No âmbito urbano, além desta contribuição, trouxeram também novos desafios tecnológicos para que se possa utilizar todo o potencial destas imagens. Se antes havia imagens cujos

pixels englobavam mais de uma edificação, nas imagens de alta resolução tem-se edificações englobando vários pixels, que podem ser representados com uma maior quantidade de níveis de cinza. A alta resolução espacial permite realizar mapeamentos em escalas maiores, identificando feições urbanas como edificações e ruas, com maior acurácia nos valores de coordenadas geodésicas (JIN e DAVIS, 2005). Já a alta resolução radiométrica permite distinguir mais tonalidades na imagem, podendo diferenciar mais detalhadamente as feições presentes na imagem.

Como exemplo de imagens de satélite de alta resolução espacial e radiométrica, atualmente, são as fornecidas pelo satélite GeoEye-1, que possui um sensor Pancromático e outro Multiespectral, com as características descritas no Quadro 01, a seguir.

| Sensor | Bandas | Resolução Espectral | Resolução Espacial | Resolução Temporal | Área Imageada | Resolução Radiométrica |
|----------------|--------|---------------------|--------------------|--------------------|---------------|------------------------|
| PANCROMÁTICO | PAN | 450-800 nm | 41 cm | 3 dias (máximo) | 15,2 km | 11 bits |
| MULTIESPECTRAL | MS | 450-510 nm | 1,65 m | 3 dias (máximo) | 15,2 km | 11 bits |
| | | 510-580 nm | | | | |
| | | 655-690 nm | | | | |
| | | 780-920 nm | | | | |

QUADRO 01 – SENSORES DO SATÉLITE GEOEYE® 1

FONTE: www.geoeye.com

Uma imagem GeoEye®, bem como de outros satélites de alta resolução espacial e radiométrica, possui pixels de dimensões submétricas fazendo com que uma edificação seja representada por um conjunto de pixels que, em virtude da alta resolução radiométrica, ainda introduzem grande variação de tons de cinza. Esta maior heterogeneidade e a similaridade da reflectância de certos materiais, dificultam a classificação das imagens utilizando métodos baseados apenas no valor do pixel – como o da Máxima-Verossimilhança, da Distância Mínima ou do Paralelepípedo. Uma alternativa para classificar este tipo de imagem é realizar uma segmentação, que consiste em dividir a imagens em regiões mais homogêneas, sendo que estas regiões, e não mais os pixels, serão os elementos básicos de classificação. Tal abordagem permite a introdução de outros atributos para a classificação, além dos atributos espectrais.

Uma imagem GeoEye[®], bem como de outros satélites de alta resolução espacial e radiométrica, possui pixels de dimensões submétricas fazendo com que uma edificação seja representada por um conjunto de pixels que, em virtude da alta resolução radiométrica, ainda introduzem grande variação de tons de cinza. Esta maior heterogeneidade e a similaridade da reflectância de certos materiais, dificultam a classificação das imagens utilizando métodos baseados apenas no valor do pixel – como o da Máxima-Verossimilhança, da Distância Mínima ou do Paralelepípedo. Uma alternativa para classificar este tipo de imagem é a segmentação, que consiste em dividir a imagens em regiões mais homogêneas, sendo que estas regiões, e não mais os pixels, serão os elementos básicos de classificação. Tal abordagem também permite a introdução de outros atributos para a classificação, além dos atributos espectrais.

2.2. LASER SCANNER AEROTRANSPORTADO (ALS)

O Laser Scanner, conhecido por LiDAR (*Light Detection and Ranging*) ou LaDAR (*Laser Detection and Ranging*), consiste em um sistema de Sensoriamento Remoto ativo que permite a obtenção das coordenadas de diversos pontos sobre uma superfície, de modo bastante rápido, utilizando-se da emissão de feixes LASER (*Light Amplification by Stimulated Emission of Radiation*) direcionado por um sistema de varredura optico mecânico na direção de alvos desejados. Este dispositivo pode ser instalado a bordo de aviões ou outras plataformas aéreas, podendo assim coletar informações da superfície terrestre durante um voo. A bordo desta plataforma, esta técnica é conhecida por Laser Scanner Aerotransportado ou, em inglês, *Airborne Laser Scanning*. A Figura 01 mostra esta técnica.




FIGURA 01 – SISTEMA ALS E SEUS COMPONENTES

FONTE: Adaptado de Flood e Gutelius (1997)

O ALS é um sistema composto pelos seguintes componentes principais:

- 1º. Gerador de pulso LASER (*Light Amplification by Stimulated Emission of Radiation*): a partir de um gerador de pulso, juntamente com um conjunto ótico (emissor/receptor), um pulso Laser é emitido em direção à superfície e refletido ao incidir sobre esta. O pulso é refletido e retorna ao sensor que irá registrar o intervalo de tempo do percurso do pulso laser, ida e volta, além da intensidade do sinal de retorno. A partir da posição do sensor, da direção de envio do pulso laser e do tempo registrado, é possível determinar a distância entre o sensor e a superfície refletora, bem como os valores das respectivas coordenadas do ponto.
- 2º. Sistema de Varredura: consiste em um sistema optico-mecânico que direciona o pulso laser. Este sistema podem ter mecanismos de varredura do tipo espelho rotatório, espelho oscilante, tipo Palmer, scanner fibra óptica, polígono rotatório.
- 3º. GPS (*Global Positioning System*): utilizado para registrar as coordenadas tridimensionais do sensor durante o voo.
- 4º. INS (*Inertial Navigation System*): o Sistema de Navegação Inercial permite – por meio do IMU (*Inertial Measurement Unit*, ou unidade de medição inercial) que é componente do sistema – registrar a atitude do sensor que, após

processada, gera os valores dos ângulos de Euler: Ω (ω), Φ (φ) e \Kappa (κ). A seguir tem-se a explicação de cada um dos ângulos de atitude:

- ω (ω) : ângulo de atitude referente ao eixo x, sendo que o eixo x é a direção do deslocamento da aeronave. O movimento da aeronave que dá origem a este ângulo de atitude é conhecido como *Roll*, ou rolamento, um giro em torno do eixo longitudinal da aeronave.
- φ (φ) : ângulo de atitude referente ao eixo y, perpendicular ao eixo x. O movimento da aeronave que dá origem a este ângulo de atitude é conhecido como *Pitch*, ou arfagem, que é o desvio em relação ao plano horizontal, para cima ou para baixo.
- κ (κ) : ângulo de atitude referente ao eixo z perpendicular aos eixos x e y, de modo a formar um sistema dextrógiro. O movimento da aeronave que dá origem a este ângulo de atitude é conhecido como *Yaw*, ou guinada, uma mudança na direção do vôo, para esquerda ou para a direita.

A Figura 02 mostra os movimentos da aeronave *Roll*, *Pitch* e *Yaw* que dão origem aos ângulos ω , φ , e κ , respectivamente.




FIGURA 02 – MOVIMENTOS *ROLL*, *PITCH* E *YAW* DA AERONAVE
FONTE: O autor (2011)

O ALS gera dados de natureza diferente dos demais métodos tradicionais do sensoriamento remoto e, desta forma, é uma ferramenta complementar de grande valia (CENTENO, 2001). Permite obter valores representativos da altura dos objetos, atingindo exatidão de 15 cm a 25 cm, com vôos a altitudes entre 1.200 m e 2.000 m

(OPTECH, 2002). Com valores de altura, feições como residências, prédios e árvores podem ser facilmente distinguidos de pavimentos, vegetação rasteira, e gramados. (ARAKI, 2005).

A grande quantidade de pontos medidos permite gerar um Modelo Digital de Superfície (MDS), que pode ser utilizado posteriormente em processos de ortorretificação da imagem. Mais informações sobre ALS podem ser encontradas em Wehr e Lohr (1999) e Centeno (2009).

2.3. ORTORRETIFICAÇÃO DE IMAGENS

Segundo Toutin (2004), as imagens sem tratamento geralmente contém distorções geométricas, de modo que elas não podem ser usadas diretamente com bases cartográficas em um sistema de informações geográficas.

Para que a imagem possa ser explorada de modo a gerar produtos cartográficos se faz necessário realizar a ortorretificação desta. A Ortorretificação da imagem é necessária para minimizar distorções geométricas tais como as causadas pelo sensor, pela geometria de imageamento e pela variação do relevo do terreno.

A ortorretificação irá realizar a correção geométrica da imagem através da correção dos efeitos das distorção. No Quadro 02 são mostradas as possíveis distorções e as fontes de erros.

| Categoria | Subcategoria | Descrição de fontes de erros |
|-----------------------------------|-------------------------|--|
| Observação / Sistema de Aquisição | Plataforma | Variação de movimento Variação de atitude |
| | Sensor | Variação na mecânica do sensor Inclinação do ângulo de visada IFOV |
| | Instrumentos de medição | Variações com o tempo Sincronia de tempo |
| Observado | Atmosfera | Refração Turbulência |
| | Terra | Curvatura Rotação Variação altimétrica do terreno |
| | Mapa | Geóide para elipsóide Elipsóide para mapa |

QUADRO 02 – FONTES DE ERROS EM IMAGENS DE SATÉLITE

FONTE: Adaptada de Toutin (2004)

Para ortorretificar as imagens de alta resolução são utilizados modelos matemáticos físicos – também chamados de modelos rigorosos - ou modelos matemáticos generalizados. Estes modelos procuram minimizar os erros devido à influência do relevo, a curvatura da superfície terrestre (em imagens extensas), a atitude do sensor no momento da captação da imagem, a perspectiva cônica da imagem e a visada lateral dos sensores *pushbroom*.

2.3.1. Modelos matemáticos físicos

Os modelos matemáticos físicos – também chamados de rigorosos – se baseiam no princípio da colinearidade, requerem o conhecimento dos dados de posicionamento e orientação do sensor (calibração do sensor, efemérides da órbita do satélite, e atitude). Estes modelos representam o processo físico de imageamento do sensor (TAO et. al., 2000).

As empresas que atualmente comercializam imagens de alta resolução não costumam fornecer informações de posicionamento e orientação dos sensores, sendo que tais informações são fundamentais para utilizar modelos rigorosos. Este é o principal motivo da utilização de modelos generalizados, pois são aplicados independentemente do sensor ou do método de aquisição da imagem (BOCCARDO et. al., 2004).

2.3.2. Modelos matemáticos generalizados

Como alternativa para a ortorretificação de imagens de satélite de alta resolução, utilizam-se freqüentemente os chamados modelos generalizados. Tais modelos são baseados em transformações geométricas que permitem determinar a relação entre as coordenadas de pontos do espaço imagem (x, y) e as coordenadas de pontos em três dimensões do espaço objeto (X, Y e Z). Desta forma, para a utilização deste modelos, formam-se assim dois conjuntos de pontos: os Pontos de Controle (PCs) e os Pontos de Verificação (PVs).

Os Pontos de Controle (PCs) – também chamados *ground control points* – devem estar bem distribuídos no espaço imagem e no espaço objeto, para se obter uma boa ortorretificação, com qualidade uniforme em toda a imagem. Simultaneamente se escolhe Pontos de Verificação (PVs) – também chamados *check points* – que irão atestar a qualidade da ortorretificação.

Em um trabalho de revisão da acurácia e uso das funções racionais em imagens Ikonos, Dowman e Tao (2002) explicam que os métodos que utilizam funções racionais são designados por expressões como “*Rational Polynomial Camera*”, “*Rational Polynomial Coefficients*” ou “*Rapid Positioning Capability (RPC)*”, bem como “*Rational Function Model*” (RFM). Neste trabalho os autores afirmam que os RFMs são acurados, robustos e eficientes na utilização dos dados Ikonos, sendo uma boa representação, ou aproximação, dos modelos físicos, e que sua utilização tem trazido bons resultados.

As razões polinomiais utilizadas nos RFMs são apresentadas nas equações (1) e (2), abaixo:

$$L = \frac{p_1(X_n, Y_n, Z_n)}{p_2(X_n, Y_n, Z_n)} = \frac{\sum_{i=0}^p \sum_{j=0}^q \sum_{k=0}^r a_{ijk} X_n^i Y_n^j Z_n^k}{\sum_{i=0}^p \sum_{j=0}^q \sum_{k=0}^r b_{ijk} X_n^i Y_n^j Z_n^k} \quad (1)$$

$$C = \frac{p_3(X_n, Y_n, Z_n)}{p_4(X_n, Y_n, Z_n)} = \frac{\sum_{i=0}^p \sum_{j=0}^q \sum_{k=0}^r c_{ijk} X_n^i Y_n^j Z_n^k}{\sum_{i=0}^p \sum_{j=0}^q \sum_{k=0}^r d_{ijk} X_n^i Y_n^j Z_n^k} \quad (2)$$

Nas equações (1) e (2), X_n , Y_n , Z_n são coordenadas normalizadas do ponto n no espaço objeto; L_n e C_n são as coordenadas normalizadas no espaço imagem em função de X_n , Y_n , Z_n ; e a_{ijk} , b_{ijk} , c_{ijk} , e d_{ijk} , são os coeficientes da transformação, chamados de Coeficientes Polinomiais Racionais. Os termos p , q e r representam o grau do polinômio.

Utilizando polinômio de primeira ordem, ou grau um, é possível modelar os efeitos causados pela projeção perspectiva, já com polinômios de segunda ordem pode-se modelar efeitos gerados pela curvatura da superfície terrestre, refração

atmosférica, distorções das lentes, etc. Outros efeitos podem ser modelados com polinômios de terceira ordem ou maiores (TAO et. al., 2000).

Segundo Tao e Hu (2001) *apud* Araki (2005), a resolução de polinômios racionais pode ter solução iterativa ou direta. A Transformação Projetiva – que se utiliza de polinômios racionais de primeira ordem, com os denominadores das equações (1) e (2) iguais – utilizada nesta pesquisa, faz uso da solução direta, mediante um ajustamento pelo Método dos Mínimo Quadrados (MMQ) na forma paramétrica. O Método dos Mínimos Quadrados procura ajustar um modelo matemático a um conjunto de observações, de modo que a soma dos quadrados das diferenças entre o valor estimado pelo modelo (valor observado ajustado) e os valores das observações seja mínimo (resíduos mínimos). A forma paramétrica de ajustamento se caracteriza quando os valores observados ajustados podem ser expressos explicitamente como função dos parâmetros ajustados do modelo matemático (GEMAEL, 2004), isto é

$$L_a = F(X_a) \quad (3)$$

onde L_a representa os valores observados ajustados, F é o modelo matemático, e X_a são os parâmetros ajustados do modelo matemático. No ajustamento paramétrico apenas os parâmetros são ajustados, sem ajustar as observações.

2.3.2.1. Transformação Projetiva

A Transformação Projetiva é um caso particular da transformação com modelos racionais generalizados. É uma transformação geométrica simples, sendo que seus parâmetros não necessitam de grande número de pontos de controle para serem determinados (JI; ZHANG, 2002). Relaciona dois espaços, o Espaço Imagem – a imagem em si – e o Espaço Objeto – o terreno. É definida por 15 parâmetros, nos quais os elementos de orientação exterior e interior estão implícitos (TAO et. al., 2000). Segundo Araki et. al. (2005), a relação entre as coordenadas de um ponto (X ,

Y, Z) no MDS e as coordenadas de uma imagem (L, C), pode ser descrita por uma transformação projetiva na sua forma homogênea.

De acordo com Azevedo e Conci (2003) as coordenadas homogêneas utilizam quatro valores (X, Y, Z, M) para descrever um ponto, relacionando-se com um sistema cartesiano pela relação $(X, Y, Z) = (X'/M, Y'/M, Z'/M)$, sendo que representam o mesmo ponto somente se um é múltiplo do outro. A Transformação Projetiva permite escrever as translações como elementos das matrizes de transformação, de modo que sua aplicação possa ser realizada por concatenação (multiplicação) de matrizes, sem necessitar a sua soma ou subtração vetorial em separado.

A equação matricial da transformação projetiva com coordenadas homogêneas é mostrada na equação 4, a seguir:

$$\underbrace{\begin{pmatrix} L' \\ C' \\ 0 \\ W \end{pmatrix}}_{V_1} = \underbrace{\begin{pmatrix} a_1 & a_2 & a_3 & a_4 \\ b_1 & b_2 & b_3 & b_4 \\ c_1 & c_2 & c_3 & c_4 \\ d_1 & d_2 & d_3 & 1 \end{pmatrix}}_T \cdot \underbrace{\begin{pmatrix} X \\ Y \\ Z \\ 1 \end{pmatrix}}_{V_2} \quad (4)$$

onde:

- $a_n, b_n, c_n, e d_n$: são os parâmetros da transformação projetiva e constituem a Matriz de Transformação T ou Matriz Fundamental, onde $a_1, a_2, a_3, b_1, b_2, b_3, c_1, c_2, e c_3$ são parâmetros que corrigem a rotação, a escala e a não-ortogonalidade entre eixos; $a_4, b_4, e c_4$ são parâmetros de translação; $d_1, d_2, e d_3$ são parâmetros da perspectiva da cena; e o número 1 corresponde à relação de escala entre os espaços relacionados.
- $L', C', 0 e W$: são coordenadas homogêneas dos pontos no Espaço Imagem, constituindo a Matriz V_1 ;
- $X, Y, Z e 1$: são coordenadas dos pontos no Esp. Objeto, constituindo a Matriz V_2 .

Cada ponto, no espaço Imagem e no Espaço Objeto, dá origem a uma coluna nas matrizes V_1 e V_2 , respectivamente. Comparando as equações (4) e (3), tem-se

que V_1 equivale a L_a , e T equivale a X_a . Assim, a Matriz de Transformação T (a matriz dos parâmetros ajustados) é calculada pela equação 5,

$$T = (V_1 P V_2^T)(V_2 P V_2^T)^{-1} \quad (5)$$

onde P é a matriz dos pesos das observações, sendo inversamente proporcional à variância destas, de modo a inserir a precisão das observações ao ajuste. Considerando que as todas as observações possuem a mesma precisão, a matriz peso P pode ser considerada uma matriz identidade. Assim, a equação 5 reduz-se à:

$$T = (V_1 V_2^T)(V_2 V_2^T)^{-1} \quad (6)$$

Os termos L' , C' , 0 e W são as coordenadas homogêneas de um pixel de coordenadas (L, C) , de modo que para se obter os reais valores no espaço imagem, estes valores devem ser divididos por W , conforme as equações 7.

$$L = L'/W \quad e \quad C = C'/W \quad (7)$$

Substituindo as equações, temos as relações polinomiais:

$$L = \frac{a_1X + a_2Y + a_3Z + a_4}{d_1X + d_2Y + d_3Z + 1} \quad C = \frac{b_1X + b_2Y + b_3Z + b_4}{d_1X + d_2Y + d_3Z + 1} \quad (8)$$

2.4. CLASSIFICAÇÃO DE IMAGENS DIGITAIS

A classificação de uma imagem passa necessariamente por um processo de interpretação. A interpretação é um processo inerente ao ser humano no momento em que visualiza uma imagem qualquer pois, ao observar a imagem, procura entender o que nela está presente para obter informações.

O processo de classificação de imagens realiza a identificação das feições nela presentes, de acordo com o objetivo proposto para a classificação. Sobre uma mesma imagem podem-se realizar diferentes classificações, de acordo com o objetivo proposto. Para a classificação digital de imagens, duas abordagens podem ser utilizadas: classificação com base no pixel ou classificação com base nos objetos da segmentação. As duas abordagens são explicadas nos itens a seguir.

2.4.1. Classificação com base no pixel

As classificações com base no pixel são realizadas a partir de seus valores digitais (DN, *digital number*), determinando a relação entre os valores dos pixels e as feições mapeadas (CENTENO, 2009).

As técnicas de classificação de imagens com base nos pixels podem ser divididas em dois grupos: as técnicas de Classificação Supervisionada e as de Classificação Não Supervisionada.

2.4.1.1. Classificação supervisionada

Na classificação supervisionada há a intervenção do usuário no âmbito de definir as classes desejadas e apresentar as amostras representativas destas classes (CENTENO, 2009). As amostras são subconjuntos de pixels da imagem que correspondem, segundo o conhecimento do usuário, a determinadas classes. As amostras devem ser representativas, ou seja, devem abranger uma quantidade adequada de pixels, bem distribuídos na imagem, contemplando as diversas maneiras em que cada classe se apresenta na imagem. Dentre os métodos de classificação supervisionada tem-se o Método dos paralelepípedos, o Método da distância mínima e o Método da máxima verossimilhança. Informações sobre estes métodos podem ser encontradas em Gonzales e Woods (2000) Richards e Jia (2006), e Centeno (2009).

2.4.1.2. Classificação não supervisionada

Na classificação não supervisionada o usuário não define os nomes das classes, pois não possui conhecimento suficiente sobre as feições presentes na imagem. O usuário poderá apenas pré-definir algumas características como a quantidade de classes, as bandas analisadas, o tamanho mínimo dos grupos e o critério de similaridade espectral (CENTENO, 2009). Os algoritmos de classificação não supervisionada analisam os pixels e os dividem em agrupamentos (*clusterings*) espectrais predominantes na imagem. Posteriormente o analista pode classificar esses agrupamentos como classes de cobertura de solo, seja por meio de algum conhecimento que ele possua da área analisada, ou através de visitas para verdade de campo (SANTOS et. al., 2010). A classificação supervisionada pode ser utilizada para verificar as possíveis classes presentes na imagem, antes de uma classificação supervisionada (RICHARD; JIA, 2006).

Entre os algoritmos de classificação não-supervisionada mais conhecidos, tem-se o K-Means e o *Iterative Self-Organizing Data Analysis Technique* (ISODATA), que podem ser consultados em RICHARDS e JIA (2006).

2.4.2. Classificação com base no objeto

O comportamento espectral de telhados de fibrocimento e de piso cimentados apresenta diversas tonalidades da cor cinza, podendo até mesmo apresentar tonalidades iguais. Analisando apenas estes critérios espectrais, torna-se muito difícil – senão impossível – distinguir entre um objeto e outro.

Um modo de possibilitar distinguir objetos com tais semelhanças consiste em tratar as áreas espectralmente homogêneas como objetos. A segmentação de imagens gera áreas homogêneas chamadas segmentos. A situação ideal ocorre quando cada objeto seja representada por apenas um segmento. Entretanto, é comum um objeto ser representado por mais de um segmento, dada a sua heterogeneidade espectral, bem como ocorre de um segmento englobar mais de um objeto, dada a semelhança espectral de objetos adjacentes.

A segmentação cria um conjunto de segmentos que possuem atributos (ou descritores). Como fora dito na Introdução deste trabalho, atributo é a representação numérica de alguma característica de um segmento, permitindo mensurá-lo e analisá-lo matematicamente. Desta forma cada segmento é caracterizado por um conjunto de atributos espectrais, atributos de forma (ou espaciais), e atributos de textura (espaciais/espectrais), que podem ser analisados no processo de distinção entre classes. Assim, mais do que a informação espectral, a análise com base no objeto por meio da segmentação da imagem fornece outras informações que participam do processo de classificação.

2.4.2.1. Atributos Espectrais

São atributos vinculados às características dos pixels que estão inseridos no segmento. São os atributos espectrais (ITT VIS, 2008):

- a. **Média dos valores digitais, por banda (AVGBAND):** este atributo é o valor correspondente ao valor médio dos valores digitais dos pixels do objeto, em cada uma das bandas disponíveis.
- b. **Desvio padrão dos valores digitais, por banda (STDBAND):** valor correspondente ao desvio padrão da média dos valores digitais dos pixels do objeto, em cada uma das bandas disponíveis.
- c. **Valor Máximo de pixel, por banda (MAXBAND):** valor correspondente ao maior valor digital observado nos pixels do objeto, em cada uma das bandas disponíveis.
- d. **Valor Mínimo de pixel, por banda (MINBAND):** valor correspondente ao menor valor digital observado nos pixels do objeto, em cada uma das bandas disponíveis.

- e. Razão entre bandas (BANDRATIO):** atributo que consiste em um valor determinado pela razão entre valores digitais de duas bandas espectrais. Optando-se pelas bandas R e NIR, este atributo representará o NDVI (*Normalized Difference Vegetation Index*), calculado pela equação 9, relacionando as médias dos valores digitais (*AVGBAND*) das bandas R e NIR. A constante *eps* inserida no denominador serve para evitar a divisão por zero. Esta constante é positiva e representa a menor diferença possível de ser calculada entre dois números pelo computador – valor em torno de 10^{-16} – sendo a acurácia do ponto flutuante (GILAT, 2003). O valor de NDVI calculado no ENVI EX, relacionando as médias das bandas R e NIR, apresenta valores um pouco diferentes se comparados caso fossem calculados pixel a pixel. Ou seja, calcular o valor do NDVI pixel a pixel para depois tirar a média é diferente de tirar a média dos pixels nas bandas e calcular o NDVI.

$$NDVI = \frac{AVGBAND(IRn) - AVGBAND(R)}{AVGBAND(IRn) + AVGBAND(R) + eps} \quad (9)$$

- f. Matiz ou Tonalidade (HUE):** Matiz, ou tonalidade, do sistema de cores HSI.
- g. Saturação (SATURATION):** Saturação do sistema de cores HSI.
- h. Intensidade (INTENSITY):** Intensidade do sistema de cores HSI.

2.4.2.2. Atributos de Forma

Os chamados atributos de forma são as características geométricas que podem ser mensuradas em forma de comprimentos, áreas ou relações matemáticas entre medidas do segmento, e que buscam representar a forma do objeto matematicamente, de modo que o computador possa interpretar. Cada uma destas características mensuradas é chamada de atributo ou descritor. São exemplos de atributos espaciais (ITT VIS, 2008; PEDRINI e SCHWARTZ 2008):

- a. **Área (AREA):** valor da área do segmento, em unidades de mapa. Caso o segmento possua um furo, esta área do furo é descontada.
- b. **Comprimento (LENGTH):** valor do comprimento do perímetro (limites) do segmento, somados os perímetros de possíveis furos que estejam dentro deste segmento.
- c. **Compacidade (COMPACT):** uma medida de forma que indica o quão compacto é o segmento, sendo o círculo a forma mais compacta, com valor $1/\pi$. Já um quadrado terá valor $1/2\sqrt{\pi}$. É calculado pela equação 10, a seguir:

$$Compacidade = \frac{\sqrt{4 \times \frac{Área}{\pi}}}{Perímetro} \quad (10)$$

- d. **Convexidade (CONVEXITY):** medida do quanto um polígono pode ser dito convexo ou côncavo. Para polígono convexo sem furos o valor de convexidade é 1, já para polígonos côncavos é menor que 1. É calculado pela equação 11, a seguir:

$$Convexidade = \frac{ComprimentoFecho\ Convexo}{Comprimento(Length)} \quad (11)$$

Em um Polígono Convexo, unindo-se quaisquer dois de seus pontos, o segmento de reta obtido está sempre contido no polígono. Já em um Polígono Côncavo, existem, pelo menos, dois pontos que unidos formam um segmento de reta que não se encontra contido no polígono.

- e. **Solidez (SOLIDIT):** compara a área do polígono com a área do fecho convexo no entorno do polígono, conforme a expressão 12. O valor de solidez para um polígono convexo, sem buracos, é 1.0, e para um polígono côncavo é menor que 1.0.

$$Solidez = \frac{\text{Área Polígono}}{\text{Área Fecho Convexo}} \quad (12)$$

- f. **Redondeza (ROUNDNESS):** compara a área do polígono com quadrado do diâmetro máximo do polígono, conforme a equação 13. O “diâmetro máximo” é o comprimento do eixo maior de uma caixa envolvente (*bounding box*) em torno do polígono. O valor de redondeza para um círculo é 1, e o valor para um quadrado é $\frac{4}{\pi}$.

$$Redondeza = \frac{4 \cdot \text{Área}}{\pi \cdot (\text{Eixo Maior})^2} \quad (13)$$

- g. **Fator de Forma (FORMFACTOR):** compara a área de um polígono com o quadrado do seu perímetro. Para um círculo o fator de forma é 1, e para um quadrado é $\frac{\pi}{4}$.

$$\text{Fator de Forma} = \frac{4 \cdot \pi \cdot \text{Área}}{(\text{Perímetro})^2} \quad (14)$$

- h. **Alongamento (ELONGATION):** indica a razão ou a proporção entre o eixo maior e menor do polígono, conforme a equação 15, e tais eixos são obtidos a partir de uma caixa envolvente (*bounding box*) em torno do polígono. Para um quadrado o valor é 1, e para um retângulo é maior que 1.

$$\text{Alongamento} = \frac{\text{Eixo Maior}}{\text{Eixo Menor}} \quad (15)$$

- i. **Retangularidade (RECT_FIT):** indica o quanto um polígono se aproxima da forma retangular, através da comparação da área do polígono com a área de uma caixa envolvente (*bounding box*) ao polígono. Para um retângulo o valor é 1, e para uma forma não retangular o valor é menor que 1.

$$\text{Retangularidade} = \frac{\text{Área}}{\text{Eixo Maior} \cdot \text{Eixo Menor}} \quad (16)$$

- j. **Direção Principal (MAINDIR):** indica a direção, em graus, do eixo maior do polígono em relação ao eixo x. Os valores variam de 0° a 180°, sendo que 90° significa direção Norte-Sul e 0° a 180° significa Leste-Oeste.
- k. **Eixo maior (MAJAXISLEN):** o comprimento do eixo maior de uma caixa envolvente (bounding box) em torno do polígono. O valor é baseado no tamanho do pixel no terreno, no caso da imagem ser georreferenciada. Caso não seja georreferenciada, o valor é dado em pixels.
- l. **Eixo menor (MINAXISLEN):** o comprimento do eixo menor de uma caixa envolvente (bounding box) em torno do polígono. O valor é baseado no tamanho do pixel no terreno, no caso da imagem ser georreferenciada. Caso não seja georreferenciada, o valor é dado em pixels.
- m. **Número de furos (NUMHOLES):** representa o número de furos ou buracos inseridos no polígono.
- n. **Relação área / furos (HOLESOLRAT):** é a razão entre a área do polígono e a área do contorno. A área do contorno é a área da parte não vazia do polígono, quando este possui buracos. O valor será igual a 1 quando o polígono não possuir furos.

$$\text{Relação área / furos} = \frac{\text{Área total do polígono}}{\text{Área do contorno}} \quad (17)$$

2.4.2.3. Atributos de Textura

Outra maneira de caracterizar objetos é através da sua textura. Para mensurar a textura de uma região da imagem, analisa-se a distribuição ou a frequência das tonalidades de cinza dentro desta. O valor da textura é calculado

para o pixel central de uma matriz quadrada móvel – se desloca na imagem – de tamanho $n \times n$ pixels chamada *kernel*, em que o valor do pixel central (n é ímpar) é modificado em função dos pixels compreendidos no *kernel*. O software ENVI EX permite alterar o tamanho do *kernel*, sendo que o tamanho padrão é 3×3 .

A textura costuma a ser mensurada através de modelos estatísticos, estocásticos e estruturais (OLIVEIRA, 2006). São exemplos de atributos de textura (ITT VIS, 2008):

- a. **Intervalo da textura (TX_RANGE):** corresponde ao intervalo de valores dos *pixels* compreendidos dentro do *kernel*.
- b. **Textura média (TX_MEAN):** corresponde à média dos valores dos *pixels* compreendidos dentro do *kernel*.
- c. **Variância da textura (TX_VARIANC):** corresponde à variância dos valores dos *pixels* compreendidos dentro do *kernel*.
- d. **Entropia da textura (TX_ENTROPY):** corresponde ao valor médio da entropia dos valores dos *pixels* compreendidos dentro do *kernel*.

2.4.2.4. Classificação utilizando apenas atributos espectrais

A classificação de imagens com base apenas em atributos espectrais é difícil – senão impossível – quando se procura distinguir feições espectralmente parecidas. A classificação pixel-a-pixel torna-se limitada ao lidar com imagens de cenas muito heterogêneas e grande variação de classes (SCHIEWE e TUFTE, 2001). Este é o caso das imagens urbanas, onde há grande variação espectral nas feições, bem como grande variação de tamanhos e formas. Objetos bastante distintos no mundo real, não são tão discerníveis quando analisados apenas com características espectrais, em duas dimensões e através de uma interpretação automatizada.

2.4.2.5. Classificação utilizando atributos espectrais, de forma e de textura

A capacidade de interpretação – e conseqüentemente de classificação – do ser humano é muito maior que a de um computador, pois o ser humano consegue considerar muito mais atributos do que aqueles que, até o momento, podem ser considerados em algoritmos computacionais. Uma pessoa, ao interpretar objetos do mundo real, considera atributos espectrais, espaciais, de contexto, de localização, etc. Incluir todo esse conhecimento em um algoritmo, toda esta quantidade de características perceptíveis ao ser humano, é uma tarefa bastante complexa.

Apesar destas limitações, a utilização de computadores apresenta a vantagem de poder considerar características observadas nas muitas bandas espectrais, e isso é mais difícil para ser humano (CENTENO, 2003). Também é capaz de identificar pequenas diferenças de tonalidades nas imagens, pois tais tonalidades são registradas como números inteiros, os valores digitais, que são diferenciados pela máquina. Os computadores, neste sentido, são bem mais capazes que o ser humano.

A utilização de atributos espaciais é fundamental para uma boa classificação de imagens de alta resolução, permitindo lidar com a grande heterogeneidade espectral dentro de uma mesma feição do terreno (objeto). Os atributos de forma e de textura contribuem para a melhor classificação automática de imagens, pois com estes atributos é possível distinguir segmentos com características espectrais semelhantes, mas forma ou texturas diferentes, como uma edificação com telhado de fibrocimento e uma rua pavimentada com cimento asfáltico.

Um dos objetivos específicos desta pesquisa é o de verificar quais são atributos que mais contribuem para identificar edificações em imagens de alta resolução de ambientes urbanos, utilizando, simultaneamente, dados ALS.

2.5. SEGMENTAÇÃO DE IMAGENS DIGITAIS

Segundo Gonzalez e Woods (2000), a segmentação consiste em dividir a imagens em suas partes ou objetos constituintes. A segmentação simplifica a

imagem, pois a divide em regiões mais ou menos homogêneas, facilitando sua análise. Estas regiões têm a característica de possuírem alguma uniformidade com relação a uma propriedade da imagem, além de cada região contrastar em relação a sua vizinhança imediata (MOIK, 1980).

Toda a segmentação deve atender aos requisitos listados no Quadro 03, a seguir :

| REQUISITO | EXPLICAÇÃO |
|---|--|
| a) $\bigcup_{i=1}^n R_i = I$ | <i>A segmentação deve ser completa, em toda a imagem, de modo que a união de todas as regiões R_i corresponda à imagem total I.</i> |
| b) R_i é conexa, $i = 1, 2, \dots, n$ | <i>Os pixels de uma região devem ser conexos, ou seja, devem ser conectados uns aos outros.</i> |
| c) $R_i \cap R_j = \emptyset, \forall i \neq j$ | <i>As regiões devem ser disjuntas, sem sobreposições.</i> |
| d) $P(R_i) = \text{Verdadeiro}$, para $i = 1, 2, \dots, n$ | <i>Todos os pixels de uma mesma região R_i devem possuir uma mesma característica (mesmo predicado), por exemplo, o valor de intensidade dentro do mesmo intervalo.</i> |
| e) $P(R_i \cup R_j) = \text{Falso}$, para $i \neq j$ | <i>Duas regiões R_i e R_j possuem características (predicados) diferentes.</i> |

QUADRO 03 – REQUISITOS BÁSICOS DA SEGMENTAÇÃO

FONTE: Gonzales e Woods, 2000

Não há um método de segmentação comum a todas as imagens, haja vista a diversidade de aplicações do Processamento de Imagens, bem como pelo fato de que a segmentação está intrinsecamente ligada a conceitos subjetivos do analista (ANTUNES, 2005). Assim, a segmentação será feita de acordo com o objetivo da análise e o conhecimento a priori sobre a imagem. A escolha da melhor técnica de segmentação é fundamental, pois a futura classificação da imagem será realizada sobre os segmentos gerados. As técnicas de segmentação se baseiam na detecção de descontinuidades e similaridade (GONZALES e WOODS, 2000).

A seguir são descritas, sucintamente, algumas das técnicas de segmentação mais utilizadas no processamento de imagens, bem como aquelas voltadas para imagens de sensoriamento remoto. Será dada maior ênfase à técnica *Full-Lambda Schedule Algorithm* (FLSA), pois esta é utilizada nesta pesquisa.

2.5.1. Segmentação por detecção de descontinuidades

A descontinuidade em uma imagem digital refere-se às mudanças bruscas do valor de cinza percebida através de um processo convolutivo com uso de máscaras. Ou seja, conforme uma máscara - uma janela 3 x3 pixels, por exemplo - percorre uma imagem, é verificada a diferença entre o valor do pixel central da janela e seus vizinhos. A descontinuidade acontece quando esta diferença supera um limiar pré-determinado, podendo detectar pontos, linhas ou bordas (polígonos). Sobre este assunto recomenda-se Gonzalez e Woods (2008) e Centeno (2004). A seguir comenta-se sobre a detecção de bordas.

2.5.1.1. Detecção de bordas

Define-se borda como a fronteira entre regiões cujos valores digitais predominantes são suficientemente diferentes. Para realizar a detecção de bordas são utilizados os operadores gradiente (∇f) e o laplaciano ($\nabla^2 f$), que são aproximados por máscaras de convolução 3 x 3, como as que são mostradas na Figura 03 (FILHO; NETO, 1999).

No entanto, as bordas não são perfeitamente caracterizadas sem que haja um tratamento posterior na imagem. Isto porque ruídos, não uniformidade da iluminação, etc., introduzem descontinuidades na bordas (GONZALEZ; WOODS, 2000).

| Detecção de pontos | Detecção de retas (verticais) | Detecção de bordas (Prewitt) | Detecção de bordas (laplaciano) | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
|--|-------------------------------|------------------------------|---------------------------------|----|---|----|----|----|----|--|----|---|----|----|---|----|----|---|----|---|----|----|----|---|---|---|---|---|---|--|---|----|---|----|---|----|---|----|---|
| <table><tr><td>-1</td><td>-1</td><td>-1</td></tr><tr><td>-1</td><td>8</td><td>-1</td></tr><tr><td>-1</td><td>-1</td><td>-1</td></tr></table> | -1 | -1 | -1 | -1 | 8 | -1 | -1 | -1 | -1 | <table><tr><td>-1</td><td>2</td><td>-1</td></tr><tr><td>-1</td><td>2</td><td>-1</td></tr><tr><td>-1</td><td>2</td><td>-1</td></tr></table> | -1 | 2 | -1 | -1 | 2 | -1 | -1 | 2 | -1 | <table><tr><td>-1</td><td>-1</td><td>-1</td></tr><tr><td>0</td><td>0</td><td>0</td></tr><tr><td>1</td><td>1</td><td>1</td></tr></table> | -1 | -1 | -1 | 0 | 0 | 0 | 1 | 1 | 1 | <table><tr><td>0</td><td>-1</td><td>0</td></tr><tr><td>-1</td><td>4</td><td>-1</td></tr><tr><td>0</td><td>-1</td><td>0</td></tr></table> | 0 | -1 | 0 | -1 | 4 | -1 | 0 | -1 | 0 |
| -1 | -1 | -1 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| -1 | 8 | -1 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| -1 | -1 | -1 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| -1 | 2 | -1 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| -1 | 2 | -1 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| -1 | 2 | -1 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| -1 | -1 | -1 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 0 | 0 | 0 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 1 | 1 | 1 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 0 | -1 | 0 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| -1 | 4 | -1 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 0 | -1 | 0 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |

FIGURA 03 – EXEMPLOS DE MÁSCARAS DE FILTROS

2.5.2. Segmentação por detecção de similaridades

A detecção de similaridade não verifica as bordas das regiões, mas sim o interior destes. Assim, a similaridade entre pixels vizinhos caracteriza uma região, pois a ideia básica é de que esta deva ter um grau de homogeneidade relativo a alguma de suas propriedades. No caso de imagens digitais a característica observada é o valor do pixel. As principais técnicas são: limiarização, divisão e fusão, crescimento de regiões, detecção de bacias (*watershed*) e deslocamento pela média (*meanshift*). Maiores informações em Gonzalez e Woods (2008), Comaniciu e Meer (2002) e Dai et. al. (2008).

2.5.2.1. Crescimento de regiões (*region growing*)

O método de crescimento de regiões inicia-se por uma segmentação incompleta, seguido de um processo que visa agregar às regiões iniciais os pixels não rotulados, aumentando estas regiões. Tais regiões iniciais são chamadas “sementes”. O processo de crescimento se dá pela decisão de quais pixels vizinhos deverão se juntar à região segundo um algum critério que reflita a similaridade de propriedades entre o pixel e a região (KÖTHE, 1995). Existem diversos critérios de similaridade possíveis de serem adotados, podendo-se considerar a similaridade de valor espectral, de textura, etc. A escolha do critério de similaridade a ser adotado depende do problema a ser resolvido, bem como do tipo de imagem analisada. Como exemplo, para analisar uma imagem de satélite para se distinguir tipos de uso do solo, é necessário considerar a cor das regiões como critério.

Outra questão a considerar até quando uma região deverá crescer, ou seja, o critério de parada. Além do critério de similaridade espectral, podem ser somados critérios de tamanho ou forma. Tais critérios consideram o histórico do crescimento da região, melhorando os resultados deste método de segmentação (GONZALEZ e WOODS, 2008).

2.5.2.2.Divisão e fusão (*splitting and merging*)

Este método inicialmente subdivide a imagem em um número arbitrário de regiões distintas para então continuar a subdividi-las ou fundi-las, numa tentativa de satisfazer os critérios básicos da segmentação, descritos no item 2.5 (GONZALEZ e WOODS, 2008). Uma maneira de realizar este método consiste em inicialmente subdividir a imagem pela técnica *quadtrees*, onde cada região, quando não atende um critério de homogeneidade, é subdividida em outras quatro. Deste modo, ao fim deste processo, quando não há mais subdivisões a serem feitas, normalmente existem regiões com propriedades similares. Assim, inicia-se o processo de fundir tais regiões.

2.5.3. *Fractal Net Evolution Approach* – FNEA

O FNEA (*Fractal Net Evolution Approach*) é um segmentador multiresolução – desde uma escala menor (mais grosseira) até uma escala maior (mais detalhada) – que permite segmentar a imagem em diferentes níveis hierárquicos, fazendo uso de conceitos da lógica *Fuzzy* e de semântica (HAY et al., 2003; ANTUNES, 2003). A hierarquia permite diferenciar classes de objetos em diferentes escalas e a semântica permite inserir o conhecimento do usuário (HAY et al., 2003).

Este segmentador está disponível no software comercial e-Cognition e faz uso de atributos espectrais, de forma, de posição e de textura. Maiores detalhes sobre segmentação multiresolução e o segmentador FNEA são encontradas em Baatz e Schaepe (2000), Hay et al. (2003) e Antunes (2003).

2.5.4. *Full Lambda-Schedule Algorithm* - FLSA

O algoritmo *Full Lambda-Schedule* foi criado por Robinson, Redding e Crisp (2002), – baseado no trabalho de Koepfler et. al. (1994) – para ser utilizado com

imagens SAR (Syntetic Aperture Radar), entretanto tem aplicabilidade geral (CRISP et. al., 2003). É um algoritmo iterativo e multi-escala que obtém ótimos resultados, mas com alto custo computacional (tempo e memória). Algumas implementações buscaram diminuir estes custos, e.g. Crisp e Tao (2002), também obtendo bons resultados.

Com abordagem de detecção de bordas e posterior fusão de regiões, o FLSA divide a imagem em regiões O_i para depois fundir regiões conexas, quando o valor do custo de fusão (c) superar um limite estabelecido, o parâmetro de escala (λ_{limite}).

O valor calculado para o custo de fusão considera variáveis espectrais e espaciais, sendo maiores quanto mais heterogêneos e maiores forem os segmentos, e menor quanto maior for a fronteira entre estes segmentos. Assim, segmentos com menor diferença espectral e menores áreas são mais fáceis de fundir, conforme pode ser observado na Equação 18, a seguir:

$$c(O_i, O_j) = \frac{|O_i| |O_j|}{|O_i| + |O_j|} \frac{\|u_i - u_j\|^2}{l(\partial(O_i, O_j))} \quad (18)$$

onde,

$c(O_i, O_j)$ = custo de fusão para unir as regiões conexas O_i e O_j

$|O_i|$ = área da região i da imagem $|O_j|$ = área da região j da imagem

u_i = valor espectral médio da região i u_j = valor espectral médio da região j

$\|u_i - u_j\|^2$ distância euclidiana entre valores espectrais das regiões i e j

$l(\partial(O_i, O_j))$ = comprimento da fronteira entre O_i e O_j

Segue o cronograma λ -schedule, mostrado na expressão 19, de ordem crescente de valor de custo de fusão. Assim, o algoritmo verifica dentre toda a vizinhança do segmento, qual a fusão de menor custo, para então fundir. Segue esta rotina até o momento em que toda a vizinhança possui custo de fusão superior ao parâmetro de escala limite λ_{limite} (KOEFLER et. al., 1994; CRISP e TAO, 2002), conforme mostrado na expressão 20. A cada fusão realizada, atualiza o cronograma informando sobre o novo segmento formado e determina sua respectiva vizinhança, além disso, o valor c que permitiu tal fusão é apagado (ROBINSON et. al., 2002).

$$0 < \lambda_1 < \lambda_2 < \lambda_3 < \dots < \lambda_n \quad (\lambda\text{-schedule}) \quad (19)$$

$$c(O_i, O_j) < \lambda_{limite} \quad (\text{condição de fusão}) \quad (20)$$

Segundo Robinson et. al. (2002) o algoritmo *full λ -schedule*, de maneira resumida, segue os seguintes passos:

1. Primeiramente toma a imagem em sua segmentação trivial, quando cada pixel é uma região.
2. De todos os pares de regiões da vizinhança, encontra o par (O_i, O_j) com menor custo de fusão c .
3. Funde as regiões O_i e O_j para formar a região O_{ij} .
4. Repete os passos 2 e 3 até que haja apenas uma região, ou até que $c(O_i, O_j) > \lambda_{limite}$ para todos os pares.

No software ENVI EX, da empresa ITT Visual Information Solutions (ver item 4.3), este algoritmo foi implementado e realiza a segmentação em duas etapas, reguladas por dois índices percentuais: *Scale Level (SL)* e *Merge Level (ML)*.

O *Scale Level* realiza a segmentação em si, e o *Merge Level* refina os segmentos. Definindo-se valores altos para SL, formam-se segmentos maiores, mas em menor quantidade, sendo uma segmentação mais grosseira. Assim, valores baixos de SL formam segmentos menores, mas em maior quantidade, podendo gerar uma supersegmentação (*oversegmentation*). Já o *Merge Level* é utilizado para refinar a segmentação, inserindo segmentos menores dentro de segmentos de maiores, diminuindo a possibilidade de supersegmentação pelo excesso de segmentos muito pequenos.

2.6. ÁRVORES DE DECISÃO

A árvore de decisão é um método de aprendizado de máquina, que simula o aprendizado humano por indução, e que pode ser utilizado para geração de regras de classificação. A indução é um processo de raciocínio de generalização que visa, a partir de amostras representativas do mundo real, ser capaz de identificar (classificar) adequadamente amostras semelhantes.

Para obter o conhecimento com aprendizado indutivo, que vai do particular ao geral, as árvores de decisão realizam primeiro uma classificação de amostras, indo do geral ao particular. Realizam um particionamento recursivo dos dados amostrais por meio de decisões sobre os atributos destas amostras, ramificando-as em subgrupos, partindo de um agrupamento geral e heterogêneo de amostras, até agrupamentos específicos e homogêneos. Tais decisões são realizadas em ordem decrescente de significância, ou ganho de informação, de modo que as decisões (testes) que melhor separam as amostras são realizadas primeiramente, avaliando o atributo mais significativo. Define-se então, o mais rápido possível, a classe da amostra. O objetivo é gerar a árvore de decisão mais simples possível, sendo pequena e eficiente. A classificação é supervisionada, pois é feita com amostras de classes finais determinadas pelo usuário. A denominação “árvore” é porque as partições recursivas das amostras produzem uma ramificação num formato de árvore invertida, como mostra a Figura 04, a seguir.

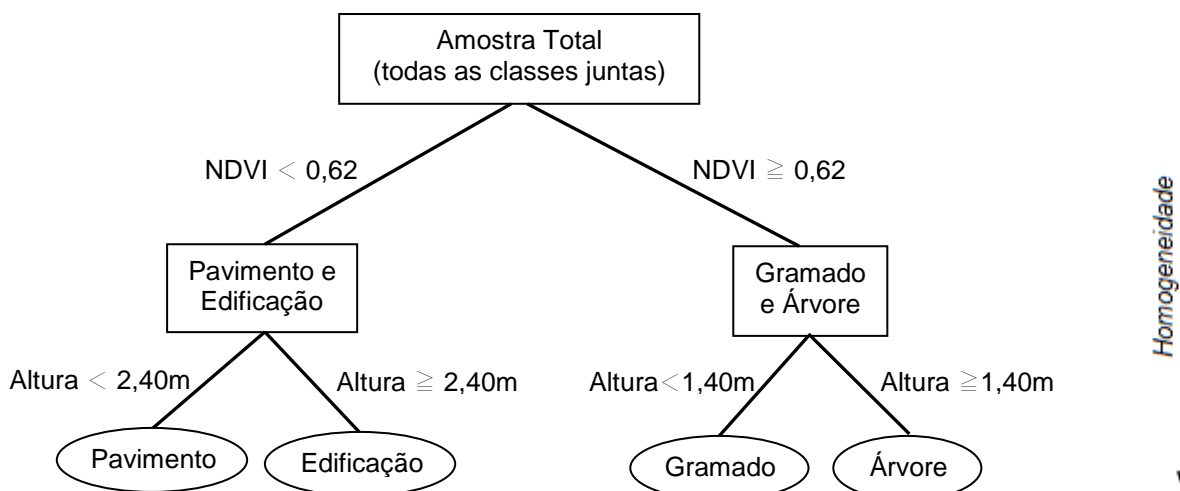


FIGURA 04 – EXEMPLO DE ÁRVORE DE DECISÃO; A HOMOGENEIDADE AUMENTA À MEDIDA QUE A ÁRVORE CRESCE
FONTE: O autor (2011)

Árvores de decisão vêm sendo muito utilizadas no meio científico por serem capazes de realizar classificações de modo simples, gerando regras de classificação de fácil compreensão.

Nesta pesquisa será utilizado o algoritmo J48, que é uma adaptação do algoritmo C4.5 e, por isso, os conceitos explicados a seguir foram obtidos de bibliografias que se referem ao C4.5, logo este algoritmo é citado várias vezes.

2.6.1. Elementos e objetivos de uma árvore de decisão

Uma árvore de decisão é composta pelos seguintes elementos:

- **Raiz:** nó inicial da árvore, no topo, onde se realiza o teste com o atributo mais significativo. Na Figura 04, o retângulo nomeado “*Amostra Total (todas as classes juntas)*” é a raiz da árvore.
- **Nós:** onde se realiza um teste sobre algum atributo das amostras. Na Figura 04, os retângulos nomeados “Pavimento e Edificação” e “Gramado e Árvore” são exemplos de nós.
- **Ramos:** são os possíveis valores assumidos pelo atributo, os resultados do teste. Cada resultado (dado discreto) conduz a outro nó, a uma sub-árvore ou a uma folha. Na Figura 04, as retas são os ramos da árvore.
- **Folha:** é a classe da(s) amostra(s); o último nó em uma regra de decisão, sendo a conclusão desta regra. Na Figura 04, as elipses nomeadas Pavimento, Edificação, Gramado e Árvore são as folhas das árvores, ou seja, as classes.

Uma regra de decisão representa o percurso percorrido pela amostra desde a raiz até uma classificação qualquer. As regras são disjuntas, independentes, logo podem ser utilizadas em separado.

De acordo com Safavian e Landgrebe (1991), os classificadores por árvores de decisão buscam:

- a) classificar corretamente o maior número de amostras de treinamento possível;
- b) classificar corretamente as amostras de treinamento, ou seja, ter capacidade de generalização;
- c) permitir fácil atualização das amostras;
- d) possuir estrutura mais simples possível.

2.6.2. Construção da árvore de decisão

Na construção da árvore de decisão é feito o particionamento recursivo das amostras, o método de “dividir e conquistar”. Dado a amostra A , que será dividida nas classes $\{C_1, C_2, \dots, C_k\}$, este método irá lidar com as seguintes possibilidades (QUINLAN, 1986 ; KOHAVI; QUINLAN, 1999):

- se todos os casos da amostra pertencem à mesma classe C_j , tem-se uma folha rotulada como C_j ;
- se a amostra não apresenta nenhum caso, a árvore também decide por uma folha, mas a classe associada a ela será a mais freqüente (a da maioria dos casos);
- se a amostra pertence a mais de uma classe, ela é dividida em amostras menores $\{A_1, A_2, \dots, A_n\}$, mais homogêneas. Assim, o nó será identificado como nó de decisão e dará origem a novos nós, que por sua vez poderão dar origem a novas sub-árvores ou folhas. Estes nós são interligados por ramos que representam os resultados $\{R_1, R_1, \dots, R_n\}$ – mutuamente exclusivos – possíveis do teste.

Estas possibilidades são verificadas recursivamente em todos os nós, ou seja, para todos os subconjuntos das amostras de treinamento.

Segundo WITTEN e FRANK (2005), existem duas diferenças ao lidar com atributos nominais ou tributos numéricos:

- Ao lidar com atributos nominais para cada possível valor do atributo se faz uma partição, e uma vez utilizado este atributo, ele não será mais testado nas demais partições.
- Ao lidar com atributos numéricos se realizam partições binárias – apenas dois galhos partindo de cada nó – calculando-se um valor de cisão tal que proporcione o maior ganho de informação. Este mesmo atributo será testado em futuras partições, podendo ser utilizado novamente como atributo de maior ganho de informação.

2.6.3. Testes candidatos e teste selecionado

Para realizar o particionamento da amostra, o C4.5 propõe três tipos de testes candidatos (QUINLAN, 1993):

- um teste padrão em um atributo discreto, tendo um ramo para cada resultado possível do teste;
- um teste mais complexo em um atributo discreto, onde diversos resultados são possíveis, sendo que será verificado o que melhor particiona a amostra;
- se um atributo U é de valores contínuos, é realizado um teste binário com um limiar Z , do tipo $U \geq Z$ ou $U < Z$.

Os testes candidatos são avaliados buscando selecionar aquele que separa a amostra em subconjuntos mais homogêneos possíveis, chegando o mais próximo de uma folha. O teste selecionado será aquele cujo atributo obtém o maior ganho de informação ou razão de ganho, sendo o mais significativo. Pelo fato de sempre dividir a amostra avaliando o atributo mais significativo, tende a gerar uma árvore eficiente (pequena). Apesar disso, para aumentar a eficiência da árvore de decisão, posteriormente pode-se utilizar de procedimentos de poda (*pruning*) da árvore ou critérios de parada, de modo a eliminar redundâncias e evita a superadaptação aos dados de treinamento (*overfitting*). Critérios de parada não são abordados nesta pesquisa. Já os conceitos de poda e superadaptação são abordados mais adiante.

Para definir o atributo mais significativo é necessário conceituar entropia (informação potencial), ganho de informação, e razão de ganho.

2.6.3.1. Entropia ou Informação potencial

A entropia, de acordo com a teoria da informação, é uma medida que expressa o grau de desordem da informação. Em uma árvore de decisão, a entropia

quantifica o grau de heterogeneidade, ou impureza, de uma determinada partição de amostras realizada por um atributo. Em outras palavras, a entropia mensura a quantidade média de informação necessária para identificar a classe das partições (subconjuntos) da amostra (QUINLAN, 1993). Quanto maior a entropia, maior a impureza da amostra. Uma árvore de decisão realiza partições recursivas que diminuam a entropia dos subconjuntos gerados, obtendo subconjuntos mais homogêneos – com menor entropia – passíveis de uma classificação adequada.

Dado um determinado atributo que pode assumir n valores, a entropia S de um dos subconjuntos gerado é calculada pela equação 21, a seguir:

$$Entropia(S) = -\sum_{i=1}^n p_i \log_2(p_i) = -\sum_{v \in V} \frac{|S_v|}{|S|} \log \frac{|S_v|}{|S|} \quad (21)$$

onde p_i é a proporção (frequência relativa) de casos da amostra S que pertence à classe i , ou a proporção de casos de sucesso S_v dentro da amostra S . Visto que a entropia está relacionada a uma medida de informação esperada, em bits, sua formulação utiliza base logarítmica 2 (CELINSKI, 2008).

2.6.3.2. Ganho de informação

Ganho de informação é a redução da entropia, e pode ser utilizado como medida do quanto uma partição da amostra, por determinado atributo, é capaz de gerar subgrupos homogêneos. Para isso compara-se a entropia da amostra inicial (S) e a entropia dos subconjuntos (S_v). Esta medida é utilizada para seleção do teste com atributo (A) mais significativo, e é calculada pela equação 22, a seguir:

$$Ganho(S, A) = Entropia(S) - \sum_{v \in V} \frac{|S_v|}{S} \cdot Entropia(S_v) \quad (22)$$

Segundo Kohavi e Quinlan (1999), o problema com este critério é que pode tender a gerar subgrupos com apenas um caso. Tal classificação não é desejável por se tratar de um caso isolado.

2.6.3.3. Razão de ganho

Para evitar classificações de apenas um caso, como as geradas pelo uso do valor do ganho de informação como critério de seleção, pode-se utilizar do valor chamado Razão de ganho. A razão de ganho relaciona o ganho de informação com a entropia ou potencial de informação. É mostrada abaixo, na equação 23.

$$Razão\ de\ Ganho = \frac{Ganho\ (S, A)}{Entropia\ (S, A)} \quad (23)$$

Com o valor da entropia como denominador, a razão de ganho não tem valor definido para entropia nula, não possibilitando criar subgrupos com um único caso; além disso, tende a favorecer os testes de atributos com baixa entropia.

2.6.4. Superadaptação (*overfitting*)

Overfitting é uma superadaptação da árvore aos dados de treinamento, isto é, a árvore gera excelentes resultados para estes dados, mas gera resultados insatisfatórios para novos dados, como os dados de teste.

Pode ser evitado através de critérios de parada que, utilizando testes estatísticos de significância, impedem que alguns subconjuntos de dados de treinamento sejam subdivididos; ou através da remoção de partes da estrutura da árvore de decisão, após esta ter sido criada. O algoritmo C4.5 se utiliza do segundo método, a remoção de partes da árvore, chamado de poda (*pruning*) (KOHAVI; QUINLAN, 1999).

2.6.5. Poda (*pruning*)

A poda em árvores de decisões é o procedimento que reduz o tamanho da árvore, visando torná-la mais simples e eficiente, sem redundâncias. Existe o método da pré-poda e da pós-poda.

Na pré-poda, em cada nó realizam-se testes de significância estatística visando cessar o crescimento da árvore se a próxima subdivisão for de alta entropia. No caso disso ocorrer, o nó corrente é transformado em folha.

Na pós-poda a árvore desenvolve-se o máximo possível. Depois ela é submetida a uma reavaliação nó a nó, onde se calcula a taxa de erro caso a árvore seja podada no nó em questão e a taxa de erro caso a poda não seja realizada. Caso a diferença entre os valores calculados supere um limiar pré-estabelecido, a árvore é podada neste nó. A pós-poda pode ser realizada por meio de uma das duas operações citadas a seguir:

- operação *Sub-Tree Replacement* : no nó em questão, elimina-se toda a estrutura da árvore abaixo deste, transformando-se em uma folha.
- operação *Sub-Tree Raising* : nós intermediários são sobrepostos por nós posteriores, em geral pelo nó posterior com maior amostra, elevando as partes inferiores da árvore em direção a raiz.

3. ESTADO DA ARTE

A seguir são apresentados alguns trabalhos de pesquisadores de instituições de vários países, que procuraram desenvolver metodologias de extração de feições em área urbana. Em cada um dos estudos citados apresenta-se, sucintamente, a área de estudo abrangida, a metodologia proposta, os resultados e as conclusões obtidas.

3.1. ESTADO DA ARTE DA SEGMENTAÇÃO DE IMAGENS E DADOS ALS

Dentre os trabalhos que utilizaram métodos de segmentação de imagens ópticas de alta resolução e dados de *laserscanner*, em conjunto ou de forma separada, citam-se os trabalhos a seguir.

Jin e Davis (2005) utilizaram imagens fusionadas IKONOS da cidade de Columbia, Estado do Missouri, EUA, e apresentaram uma metodologia para extração automática de edificações. Utilizaram-se de informação estrutural, contextual e espectral - geometria do objeto, sombra projetada, e brilho na imagem, respectivamente - para realizar a segmentação da imagem. Cada tipo de informação foi utilizado separadamente, e, ao fim, os resultados das segmentações foram somados. As informações de geometria foram os atributos área, largura e comprimento; as informações de contexto foram as sombras projetadas pelos objetos, distinguindo entre edificações e áreas de estacionamento; e as espectrais foram o NDVI e a homogeneidade. A utilização de cada fonte de informação de maneira isolada não apresentou bons resultados, não detectando mais da metade das edificações. Isso se deve à grande variedade de construções em áreas urbanas, com grande variação de forma, tamanho, contraste, etc.. Com a integração das três fontes foi possível detectar 72,7% das edificações, com qualidade de 58,8%. Apesar dos bons resultados, os autores citaram problemas na detecção de algumas edificações com telhados de duas águas, bem como a má classificação de áreas de estacionamento de tons escuros, erroneamente designadas como edificações.

Shan e Lee (2005) mediram a qualidade da extração de edificações em imagens Ikonos, multiespectrais e pancromáticas, de uma área de 5,8 x 3,6 km², em Camp Lejeune, Carolina do Norte, EUA. Esta avaliação foi feita sobre cinco valores obtidos pela comparação da área da edificação segmentada com a da edificação real, gerando valores percentuais. Estes valores fazem parte de um índice de qualidade que varia de 0 a 1, onde 0 significa que não houve nenhuma sobreposição entre a edificação segmentada e a respectiva área no terreno, e 1 significa total sobreposição. Este índice, utilizado de modo hierárquico, difere entre edificações e “alarmes falsos”. Em uma área de 1 km², com 112 edificações reais, foram extraídos 117 segmentos. Destes, 36 foram considerados alarmes falsos, 60 tiveram qualidade de 95%, e os demais com menores índices de qualidade. Conclui-se que: (1) um controle qualitativo e quantitativo é crucial para o sucesso de implementações de extração automática de edificações; (2) os 5 valores calculados permitem uma boa compreensão da acurácia obtida na segmentação; (3) a metodologia de controle hierárquico de qualidade permite boa distinção entre construções e alarmes falsos.

Carleer et. al. (2005) realizaram um estudo de avaliação e comparação entre quatro algoritmos de segmentação aplicados sobre imagens Ikonos pancromática de Bruxelas, capital da Bélgica. Tais imagens apresentavam vários tipos de cobertura de solo como área rural, residencial, urbana administrativa, urbana mista e floresta. Foram utilizados os algoritmos Detector de bordas e *Watershed*, baseados na detecção de contornos (*boundary-based*), e Crescimento de regiões e Limiarização multinível, baseados em regiões. Verificou-se que: (1) não há nenhum método de segmentação capaz de apresentar bons resultados em todos os tipos de cobertura de solo presente nas imagens; (2) a escolha dos parâmetros, ou limiares, é importante nos quatro métodos e tem grande influência nos resultados; (3) os métodos baseados em detecção de contornos são mais sensíveis a ruídos e texturas, necessitando de pré-processamentos, como o filtro de mediana; (4) os métodos baseados em regiões apresentam problemas na transição entre objetos contrastantes; (5) o método de Crescimento de regiões é menos sensível à textura, o que é uma vantagem para segmentar imagens de alta resolução espacial; (6) o método de limiarização multinível é menos efetivo para imagens com objetos isolados, apresentando histograma unimodal, sendo aplicáveis às imagens com pouca textura.

Sohn e Dowman (2007) apresentam um estudo para extrair automaticamente contornos de edificações presentes em imagens IKONOS da região de Greenwich, Inglaterra, juntamente com o uso de dados LIDAR. As imagens, pancromáticas e multiespectrais, compreendem uma área urbana com residências e indústrias. Os dados de *laserscanner* apresentavam baixa densidade de pontos, com 0,1 ponto / m². A imagem foi ortorretificada, apresentando acurácia posicional de aproximadamente 1,9 m.

A extração dos contornos das edificações consistiu em duas etapas: detecção das edificações e descrição das edificações. Na detecção das edificações, os pontos do LiDAR foram classificados mediante um processo de árvore de decisão em três etapas: Etapa 1, classificação grosseira, diferenciando pontos pertencentes ao terreno e os não pertencentes ao terreno; Etapa 2, classificação intermediária, onde os pontos classificados como não pertencentes ao terreno foram subdivididos entre pontos altos e pontos baixos, conforme a altura de cada ponto; Etapa 3, classificação mais refinada, na qual os pontos altos foram subdivididos entre pontos pertencentes às árvores e pontos pertencentes às edificações, de acordo com um limiar de índice NDVI (igual a 0,8) obtido a partir da imagem IKONOS. Os pontos classificados como pertencentes às árvores (alto NDVI) foram eliminados, restando os das edificações (baixo NDVI).

Na descrição das edificações, os contornos das edificações foram gerados analisando a imagem IKONOS. Os pequenos segmentos detectados foram eliminados, de acordo com um limiar de comprimento (5 m), e escolheu-se apenas segmentos com uma direção predominante, de acordo com um limiar de direção, um ângulo (30°). De modo auxiliar, utilizou-se dos pontos LiDAR para detectar segmentos de contornos. Assim, os pontos LiDAR foram interpolados para aumentar a densidade, sendo que esta interpolação foi distinta para pontos pertencentes às edificações e pontos não pertencentes às edificações, para não gerar pontos com alturas sem significado físico.

A avaliação da qualidade da extração foi avaliada pelos critérios conhecidos da literatura como *Branching factor*, *Miss factor*, *Completeness*, *Correctness*, *Quality percentage*. As conclusões foram que a informação de terreno extraída do LiDAR e as informações da imagem multiespectral IKONOS proporcionam bons resultados para a detecção de edificações. A metodologia proposta pode detectar vários tipos

de edificações, sem se ater a modelos pré-determinados. Os resultados mostraram que a maioria das edificações foram detectadas e delineadas na cena.

Awrangjeb et. al. (2010) buscaram desenvolver uma técnica para integrar dados LIDAR e imagens multiespectrais ortorretificadas de Fairfield, NSW, Austrália, visando extrair edificações automaticamente. Um DEM também foi utilizado. A técnica é aplicada em quatro etapas. Na primeira etapa utilizam-se duas máscaras para detectar edificações a partir do LIDAR, sendo que a primeira máscara detecta oclusões para separar edificações muito próximas, e a segunda máscara ajuda a melhor definir as edificações quando os telhados das edificações e o terreno possuem materiais com reflectâncias parecidas. Na segunda etapa extraem-se os segmentos de “árvores” a partir de um limiar do *Normalized Difference Vegetation Index* – NDVI (T_{NDVI}) e da consideração de que segmentos que não são perpendiculares ou paralelos entre si não pertencem às edificações. Na terceira, as posições das edificações são determinadas a partir dos segmentos remanescentes. Na quarta e última etapa, com as posições iniciais das edificações obtidas no LIDAR, busca-se informações na imagem colorida para ampliar a extração.

Para avaliar a qualidade da extração, utilizaram 15 índices de qualidade, sendo 7 índices com base nos pixels, 7 índices com base nos objetos, e 1 com base na geometria das edificações. As conclusões foram que: (1) a técnica utilizada obteve sucesso na extração de edificações em área urbana ou industrial (2) a segmentação com base no objeto apresentou melhores resultados que a segmentação com base no pixel, com maiores índices de acertos (acertividade de 97% contra 78%); (3) poderão haver deficiências quando a área analisada possuir declividade significativa, com alta densidade de edificações com rápidas variações de altura, pois o DEM poderá não ser adequado; (4) a técnica pode ser aplicada com confiabilidade no planejamento urbano, prevenção de desastres como inundações e incêndios, monitoração de mudanças no uso do solo, etc.; mas ainda não é aplicável ao mapeamento cadastral, pois não possui resolução suficiente para a acurácia geométrica necessária.

3.2. ESTADO DA ARTE DA CLASSIFICAÇÃO COM ÁRVORES DE DECISÃO

Focando nos trabalhos que utilizaram árvores de decisão para classificação de imagens, citam-se os trabalhos a seguir.

Em 1997, Huang e Jensen realizaram a classificação automática de imagens SPOT de uma área de mil hectares da reserva de Par Pond, Carolina do Sul, Estados Unidos, com um sistema especialista em que a base de conhecimento foi gerada por meio de aprendizado indutivo da árvore de decisão, com dados de Sistemas de Informações Geográficas (SIG) como informação complementar. A classificação obtida foi comparada às classificações realizadas por métodos convencionais de Máxima-Verossimilhança e ISODATA, apontando para melhores resultados da classificação do sistema especialista. O estudo concluiu que: (1) por este método, a construção da base de conhecimento é mais fácil que por métodos tradicionais que necessitam da intervenção de um engenheiro de conhecimento; (2) os dados SIG, por não se ajustarem a uma distribuição Gaussiana, não são apropriados para o Método da máxima-verossimilhança; (3) utilizando árvores de decisão, que não assumem a condição de distribuição Gaussiana, os dados SIG contribuem muito para a melhora da classificação.

Matikainen et. al. (2007) estudaram a importância do uso de diferentes bases de dados e atributos para a detecção de edificações. Em uma área teste de 1,4 km², em Espoonlahti, na Finlândia, eles utilizaram: 1) dados LIDAR, “first and last pulse”, de um voo a 400 m de altura, com densidade de 10 pontos/m² e até 17 pontos/m² em áreas de sobreposição, gerando um DSM com resolução de 30 x 30 cm; 2) Foto aérea colorida, ortorretificada, com resolução de 30 x 30 cm; 3) Base cartográfica digital com resolução de 30 x 30 cm, para avaliação da qualidade, pixel a pixel, da detecção das edificações. As segmentações da imagem e dos dados LIDAR foram realizadas no e-Cognition. Já a construção da Árvore de Decisão foi feita no Matlab, utilizando a Statistics Toolbox. Foram selecionados 2224 amostras – sendo 391 das edificações e 1833 das árvores, com atributos do LIDAR, da imagem e de forma – usados em quatro testes, cada um com uma seleção de atributos específica. Tais estudos atestaram o uso de diferentes fontes de dados para a detecção de edificações, obtendo acurácias da ordem de 89% a 92%.

Gutierrez et. al. (2009) utilizaram o algoritmo C4.5 para realizar a classificação automática em dados LIDAR, sem a utilização de imagens espectrais, na região de Huelva, sul da Espanha. Neste local coexistiam áreas industriais e áreas de preservação ambiental, e a pressão por novos espaços para a ampliação do parque industrial é constante. Assim, o Sensoriamento Remoto apresentou-se como uma ferramenta importante para detectar tais espaços sem agredir o meio-ambiente. A abordagem, mesmo que sem o uso de imagens, apresenta resultados promissores, com 85% de acurácia na classificação e baixo custo computacional por utilizar apenas uma fonte de dados. Apresentou problemas na classificação de pontos isolados (*outliers*), como residências que não apresentavam estrutura típica de telhado, mas que utilizavam material semelhante ao terreno local.

Também em 2009, Da Luz et. al., utilizaram a técnica FNEA (Fractal Net Evolution Approach) para realizar a segmentação de imagens multiespectrais SPOT, de uma região com florestas, área urbana e regiões agrícolas, ao norte do Estado do Paraná, Brasil. Os segmentos tiveram seus atributos extraídos no aplicativo e-Cognition. Estes segmentos, com seus atributos, foram analisados na Árvore de Decisão do algoritmo J48 – uma adaptação do C4.5 – do software de domínio público Weka, que gerou um conjunto de regras de decisão do tipo if-then: o conhecimento. As regras foram utilizadas no Matlab, que realizou a classificação final. A classificação por regras foi comparada a duas outras classificações realizadas: Distância Mínima e Máxima Verossimilhança. As conclusões foram de que: a segmentação prévia da imagem permitiu obter melhores resultados quanto à acurácia global, acurácia por classe, redução do efeito “salt and pepper” e definição de bordas; a classificação por regras de conhecimento, apesar de menor acurácia global, obteve-se maior acurácia por classe; e para um conjunto de dados mais complexo, as regras obtiveram maior acurácia.

3.3. CONSIDERAÇÕES SOBRE O ESTADO DA ARTE

Pela revisão bibliográfica feita em artigos e livros que abordavam segmentação de imagens orbitais e dados LiDAR, verificou-se os inúmeros esforços no âmbito de se extrair automaticamente feições a partir de imagens orbitais de alta

resolução, com ou sem a utilização de dados LiDAR. O dados LiDAR têm sido alvo de vários estudos que vêm demonstrando a sua importância para a automatização na extrações de feições do terreno, fornecendo informação de altura, essencial na extração de residências. Também se verificou que diversos métodos de segmentação de imagens foram utilizados. Grande parte dos experimentos apresentou melhores resultados com métodos que realizaram a segmentação das imagens, do que os métodos que analisaram a imagem com base no pixel.

Já a revisão de literatura referente a trabalhos que abordavam árvores de decisão na classificação de imagens de alta resolução, mostrou que os estudos realizados com tais abordagens obtiveram melhores resultados, quando comparados a alguns outros métodos de classificação. A árvore de decisão, por ser um método não paramétrico, não supõe o ajuste dos dados a uma distribuição estatística conhecida, o que se adequa melhor aos dados analisados.

4. DADOS, ÁREA DE ESTUDO E RECURSOS

4.1. DADOS

A seguir são descritas as características da imagem de alta resolução espacial GeoEye[®], dos dados ALS, e da base vetorizada utilizada nesta pesquisa.

4.1.1. Imagem de alta resolução – GeoEye[®]

Para esta pesquisa foi utilizada uma imagem de satélite de alta resolução GeoEye[®], tipo Geo, que consiste em uma imagem com quatro bandas espectrais, previamente orientada, fusionada (*pan-sharpening*) e corrigida radiometricamente. As características quanto às resoluções da imagem são mostrada no Quadro 04.

| Imagem | Resolução Espectral | | Resolução Espacial | Resolução Radiométrica |
|----------------|---------------------|------------|--------------------|------------------------|
| PAN-SHARPENING | B | 450-510 nm | 50 cm | 11 bits (2048 DN) |
| | G | 510-580 nm | | |
| | R | 655-690 nm | | |
| | NIR | 780-920 nm | | |

QUADRO 04 – CARACTERÍSTICAS DA IMAGEM UTILIZADA NA PESQUISA

Desta imagem tomou-se uma parte onde existem diferentes tipos de edificações de baixa altura, como residências e sobrados, e poucas edificações altas como prédios acima de dois pavimentos. Também apresenta edificações com telhados de fibrocimento ou cerâmico, com tonalidades claras e escuras. A diversidade de tipos de telhado é uma característica importante por representar a realidade mais comum de ambientes urbanos. A baixa altura das edificações – apesar de ser uma restrição da realidade – facilita a pesquisa, porque apresenta menores áreas com oclusões, havendo menor ocorrência de áreas com duplo mapeamento quando se realiza a ortorretificação de imagem.

4.1.2. Dados de Laser Scanner Aerotransportado – ALS

Os dados ALS foram fornecidos pelo LACTEC e foram obtidos com o modelo ALTM 2050 cujas características são mostradas no Quadro 05, a seguir:

| | |
|------------------------------|------------------------------------|
| Modelo do equipamento | ALTM 2050 |
| Fabricante do equipamento | Optech |
| Ano de fabricação | 2002 |
| Frequência do pulso laser | 50.000 pulsos por segundo – 50kHz |
| Frequência de varredura | Variável de 1Hz a 100Hz |
| Ângulo de varredura | Variável 0° a 40° |
| Sistema Inercial (IMU) / GPS | Applanix |
| Capacidade de armazenamento | 36 Gigabytes |
| Software da operação de voo | ALTM-NAV (Optech) |
| Software do processamento | REALM (Optech) |
| Tipo de coleta de dados | Primeiro e último retorno do pulso |
| Densidade de pontos | Variável de 400.000 de 4.000.000 |

QUADRO 05 – CARACTERÍSTICAS DO EQUIPAMENTO DE LASERSCANNER
FONTE: LACTEC

O voo foi realizado com as características descritas no Quadro 06, a seguir.

| | |
|---|---|
| Altura de Voo | 1.000 metros |
| Densidade de pontos | $\cong 1,1$ ponto / m ² |
| Distância entre pontos | $\cong 0,984$ m (cross track res = 0,844; |
| Referencial geodésico | WGS-84 |
| Projeção Cartográfica | UTM – Fuso 22 Sul |
| Ângulo de Varredura | +/- 20° (40° total) |
| Frequência do pulso | 50 Khz |
| Frequência do espelho de varredura | 29 Hz |
| Sobreposição lateral das faixas paralelas | 50% |

QUADRO 06 – CARACTERÍSTICAS DO VÔO
FONTE: LACTEC

O vôo foi realizado sobre a região do Aeroporto do Bacacheri, visando realizar a calibração do aparelho. Este vôo possui quatro faixas de imageamento, abrangendo uma área de aproximadamente 15 km².

Os pontos ALS estão gravados em arquivos tipo texto, sendo um arquivo para o primeiro pulso e um arquivo para o último pulso, para cada faixa de vôo. Cada linha nos arquivos corresponde a um ponto, possuindo quatro colunas de informação. A primeira, a segunda, e a terceira coluna são as coordenadas E, N, h do ponto, respectivamente. Já a quarta coluna corresponde à intensidade do pulso de retorno (I). Esta disposição dos dados ALS pode ser vista na Figura 05, a seguir.

```
677729.22 7188765.01 936.69 63.00
677729.05 7188764.60 936.87 57.00
677730.81 7188765.04 936.52 64.00
677727.22 7188761.91 936.39 62.00
677737.79 7188764.70 936.48 20.00
677739.46 7188765.15 936.58 19.00
677728.00 7188760.00 936.04 69.00
```

FIGURA 05 – DADOS ALS. VALORES E, N, h, I PARA CADA PONTO

4.1.3. Base Vetorizada

Visto que não havia base cartográfica das edificações da área de estudo e para que os resultados pudessem ser avaliados quantitativamente, foi feito no gvSIG a vetorização dos contornos das edificações presentes na imagem da área de estudo. Esta vetorização foi considerada como “verdade de campo”.

A vetorização foi realizada considerando quatro tipos de cobertura de edificações, são elas: Edificações com Telha Cerâmica Escura, Edificações com Telha Cerâmica Clara, Edificações com Telha de Fibrocimento Escuro, e Edificações com Telha de Fibrocimento Claro. Tal divisão se fez em prol dos experimentos realizados nesta pesquisa, cujos resultados são mostrados no Capítulo 6.

A Figura 06 apresenta esta base vetorizada sobreposta à imagem óptica, com legendas de classes de edificação com a respectiva quantidade de feições (objetos) em cada classe. A Figura 07 apresenta esta mesma base vetorizada, mas não estando sobreposta na imagem, facilitando a visualização.

- Telha Cerâmica Escura (229 objetos) ■ Telha Cerâmica Clara (128 objetos)
■ Telha Fibrocimento Escuro (156 objetos) ■ Telha Fibrocimento Claro (83 objetos)



FIGURA 06 – BASE VETORIZADA SOBRE A IMAGEM ÓPTICA. AS LEGENDAS MOSTRAM AS CLASSES DE EDIFICAÇÃO E RESPECTIVA QUANTIDADE DE EDIFICAÇÕES (OBJETOS) ENTRE PARÊNTESES

- Telha Cerâmica Escura (229 objetos) ■ Telha Cerâmica Clara (128 objetos)
■ Telha Fibrocimento Escuro (156 objetos) ■ Telha Fibrocimento Claro (83 objetos)





FIGURA 07 – BASE VETORIZADA. AS LEGENDAS MOSTRAM AS CLASSES DE EDIFICAÇÃO E A RESPECTIVA QUANTIDADE DE EDIFICAÇÕES (OBJETOS) ENTRE PARÊNTESES

4.2. ÁREA DE ESTUDO

Os dados utilizados nesta pesquisa referem-se a uma região da zona urbana de Curitiba, bairro Bacacheri. É uma região com densa urbanização, apresentando residências próximas umas as outras. A área de estudo é chamada de Imagem Teste e, a partir desta, é extraída uma imagem menor chamada Imagem Base. A Figura 08 apresenta estas imagens e suas coordenadas. A Imagem Base foi utilizada para a coleta de amostras para geração das regras, e a Imagem Teste foi utilizada para aplicar as regras.



| Coord. Imagem Teste | | |
|---------------------|------------|-----------|
| Pt | S | E |
| A | 7188841.25 | 676903.75 |
| B | 7188841.25 | 677526.75 |
| C | 7188383.25 | 677526.75 |
| D | 7188383.25 | 676903.75 |

| Coord. Imagem Base | | |
|--------------------|------------|-----------|
| Pt | S | E |
| 1 | 7188691.75 | 677330.25 |
| 2 | 7188662.25 | 677417.75 |
| 3 | 7188631.75 | 677373.25 |
| 4 | 7188526.25 | 677518.75 |
| 5 | 7188385.25 | 677308.75 |
| 6 | 7188388.75 | 677259.25 |
| 7 | 7188563.75 | 677138.75 |

FIGURA 08 – IMAGEM TESTE (MAIOR) E IMAGEM BASE (MENOR), COM SUAS RESPECTIVAS COORDENADAS.

4.3. RECURSOS DE HARDWARE E SOFTWARE

HARDWARE: Computador Itautec S.A., Infoway, processador Intel Pentium(R) Dual Core T4200@2GHz, 2 GB de memória RAM e Windows 7.

SOFTWARE:

- a. MATLAB (*MATrix LABoratory*): software de programação de alto nível onde foram desenvolvidos programas para gerar o modelo digital de superfície (MDS) e a Imagem de Intensidade, bem como ortorretificar a imagem. Também foi utilizado para a filtragem de pixels isolados de altura elevada no MDS.
- b. ALDPAT (*Airborne LiDAR Data Processing and Analysis Tools*): software desenvolvido na *International Hurricane Research Center at Florida International University* para trabalhar com dados LiDAR. Foi utilizado para a filtragem de pontos, mediante aplicação do filtro morfológico disponibilizado no software. Assim se obteve os pontos do MDT.
- c. gvSIG 1.11: software livre, desenvolvido pela Universidade de Valencia, utilizado para construção de Sistemas de Informações Geográficas, que lida com dados em formato *raster* ou vetoriais. Foi utilizado para superposição de *shapes*, seleção de amostras de segmentos dentro das classes, e aplicação das regras geradas nas árvores de decisão.
- d. ENVI 4.6.1 (*ENvironment for Visualizing Images*): software comercial desenvolvido pela *ITT Visual Information Solutions*, para o processamento de imagens digitais. Utilizado para trabalhar com visualizações, recortes, adição e subtração de bandas em uma imagem para geração do MDSn.
- e. ENVI EX: aplicativo complementar do ENVI que, dentre outras capacidades, realiza a segmentação da imagem com o algoritmo FLSA, extraíndo atributos espectrais, de forma e de textura dos segmentos.
- f. WEKA v. 3.4.18 (*Waikato Environment for Knowledge Analysis*): desenvolvido na Universidade de Waikato, Nova Zelândia, trata-se de um software de mineração de dados que possui diversos algoritmos implementados, incluindo os que geram árvores de decisão.

5. METODOLOGIA

A metodologia proposta para esta pesquisa baseia-se, de modo geral, em quatro etapas, conforme a Figura 09. São as etapas:

1º. MDS, MDT e MDSn: geração do MDS (Modelo Digital de Superfície), do MDT (Modelo Digital de Terreno), e do MDSn (Modelo Digital de Superfície normalizado).

2º. Ortorretificação: geração da imagem ortorretificada.

3º. Segmentação e Regras: segmentação de parte da imagem ortorretificada, ou seja, segmentação da imagem menor utilizada para coleta de amostras, seguido da geração de regras de identificação

4º. Identificação: segmentação da imagem ortorretificada inteira, seguido da aplicação das regras sobre os segmentos desta imagem.

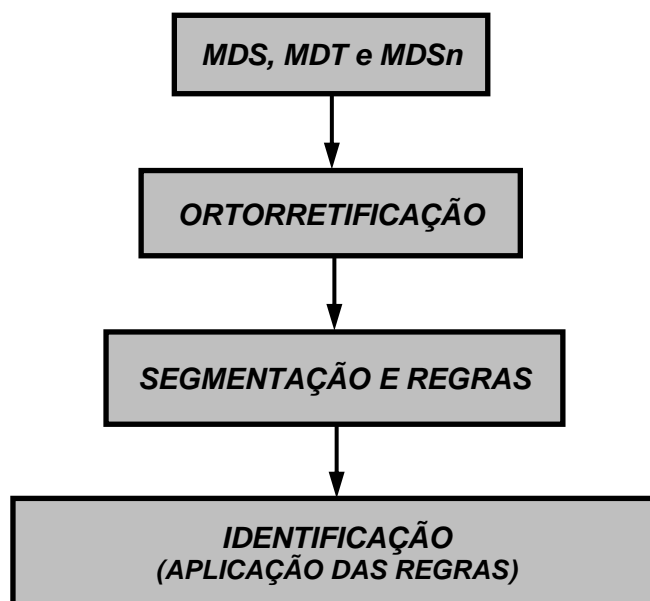


FIGURA 09 – ETAPAS GERAIS DA METODOLOGIA

De modo mais detalhado, a metodologia é apresentada na Figura 10. As etapas mostradas nesta figura são explicadas ao longo deste capítulo. A etapa de geração do MDS, MDT e MDSn, bem como a da Ortorretificação, ainda apresentam maiores detalhes, mas que foram omitidos na Figura 09 para não dificultar a compreensão da metodologia.

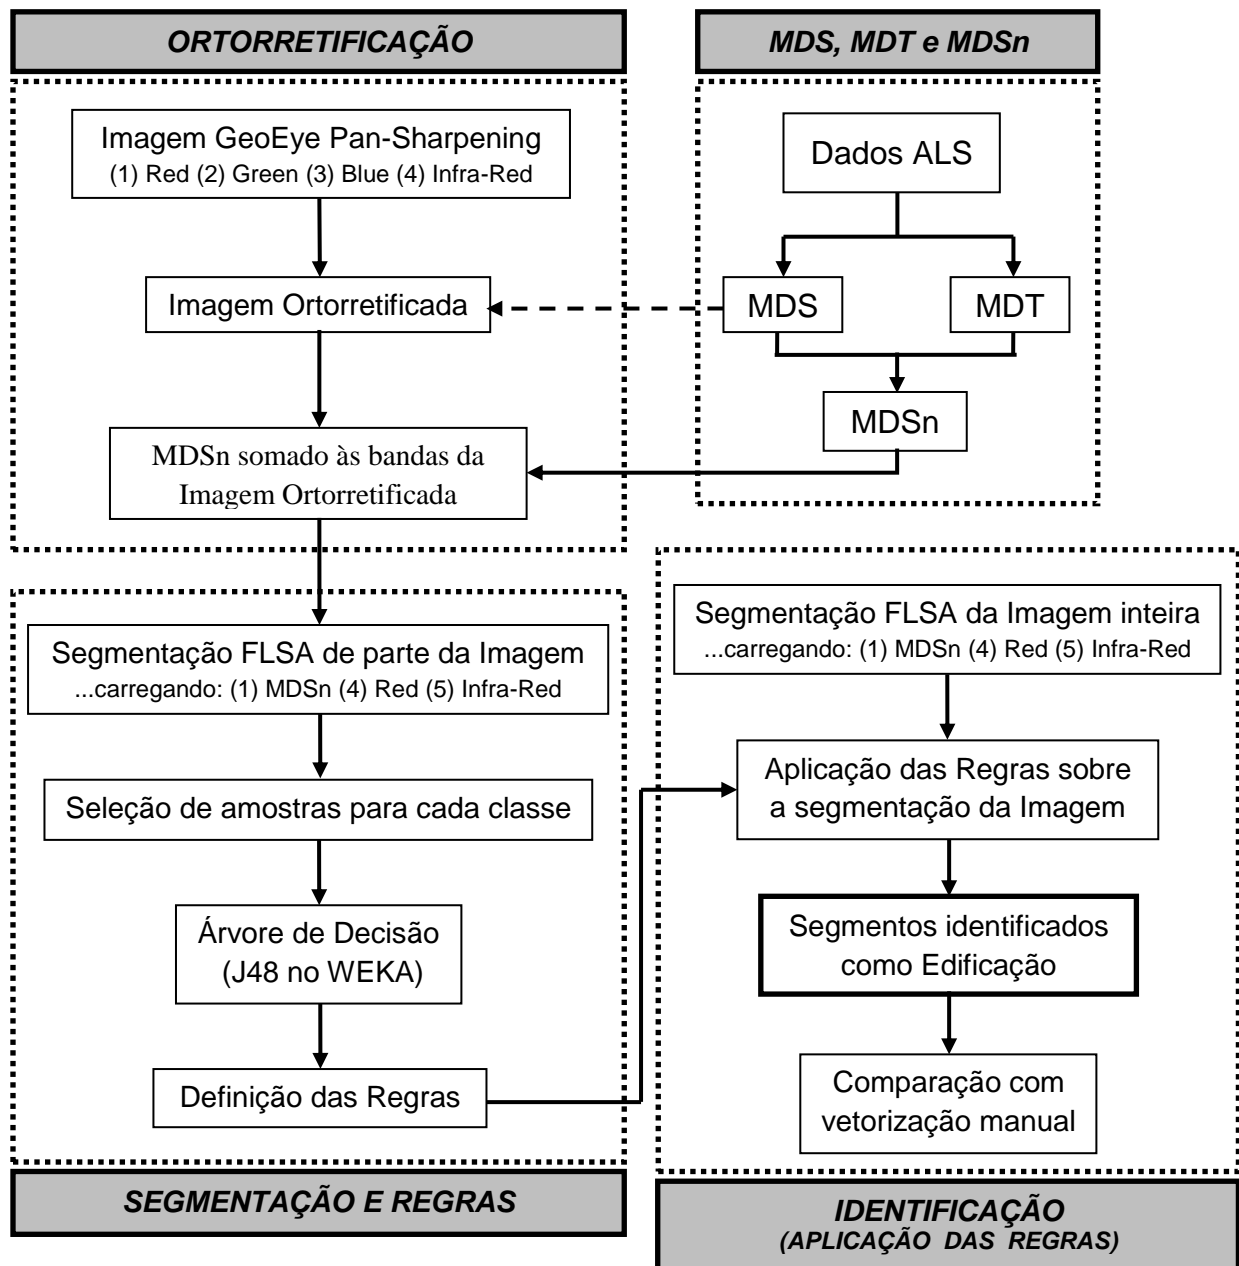


FIGURA 10 – DETALHAMENTO DAS ETAPAS DA METODOLOGIA

5.1. MODELOS DIGITAIS - MDS, MDT E MDSN

Antes de segmentar e classificar a imagem, foram realizados os procedimentos de ortorretificação da imagem e geração do MDS, do MDT, e do MDSn. Tais modelos são gerados a partir dos dados ALS para serem utilizados na

ortorretificação da imagem GeoEye (MDS) e nas segmentações (MDSn). A Figura 11 mostra estas etapas na forma de um fluxograma.

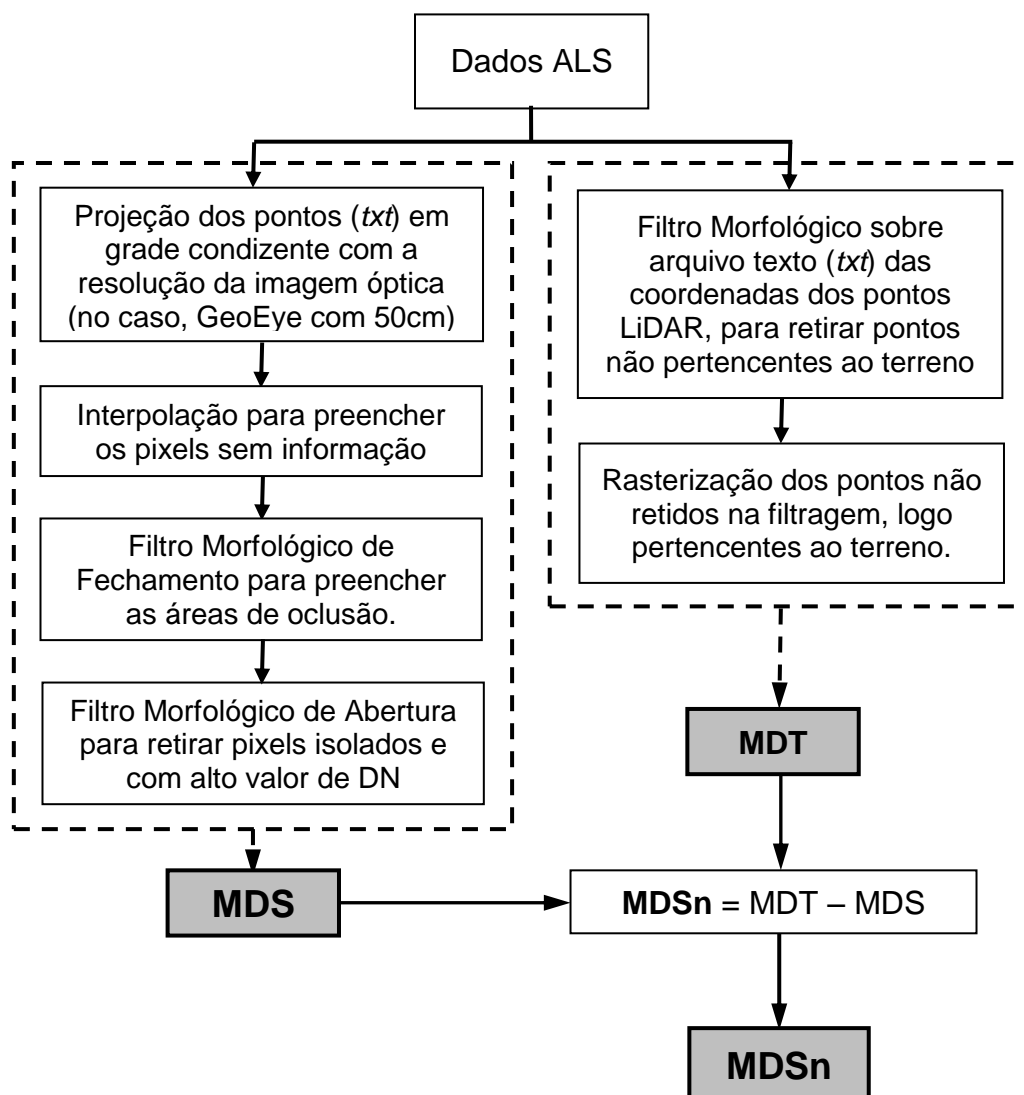


FIGURA 11 – DETALHAMENTO DA GERAÇÃO DO MDS, MDT E MDSn

5.1.1. MDS – Modelo Digital de Superfície

O MDS representa tudo o que está sobre a superfície imageada, abrangendo tanto o terreno quanto os objetos sobre o terreno, como edificações, árvores, etc.

Para gerar o MDS foi desenvolvido um programa no MATLAB[®] para ler os pontos ALS gravados em arquivos tipo texto e projetá-los em uma grade bidimensional para formar uma imagem.

5.1.1.1. Projeção dos pontos em uma grade

O MDS foi gerado para se adequar à resolução espacial da imagem GeoEye®, ou seja, foi desenvolvido para ter a resolução espacial de 50 cm. Para isso, desenvolveu-se um programa no MATLAB onde foi gerada uma grade (matriz) de tal que abrangesse todos os pontos ALS coletados para a área de estudo, isto é, a grade gerada abrangia deste o ponto de menor coordenada E e maior coordenada N (canto superior esquerdo), até o ponto de maior coordenada E e menor coordenada N (canto inferior direito). Entre estes dois extremos, foram criadas células a cada 50cm em ambas as direções, estando de acordo com a resolução da imagem GeoEye. Visto que os pontos resultantes do levantamento ALS estavam espaçados de cerca de 0,98m – separação maior que a resolução da imagem –, a simples projeção dos pixels na grade gerou um MDS com diversos pixels sem informação (buracos ou furos na imagem ALS), como pode ser visto na Figura 12.




FIGURA 12 – PARTE DO MDS, RESOLUÇÃO 50cm; NECESSITA INTERPOLAÇÃO E OP. MORFOLÓGICA DE FECHAMENTO

Para o preenchimento destes os pixels sem informação, foram realizadas duas operações sobre o MDS: a Interpolação e a Operação Morfológica de Fechamento. A interpolação preenche apenas os pixels vazios da imagem nas áreas sem oclusão, onde a presença de pixels não preenchidos se deve principalmente a diferença de resolução do levantamento ALS (0,98 pontos/m²) frente à resolução espacial da imagem (50cm). Já a operação de fechamento afeta todos os pixels,

preenchendo as regiões de oclusão sem criar novos valores de pixel, como ocorre na interpolação. Interpolações nas regiões de oclusão causariam um efeito de “*dégradé*” nos valores digitais, criando uma superfície inclinada não coerente com a realidade.

A situação ideal seria que a densidade do levantamento ALS fosse de, no mínimo, 4 pontos/m², o que minimizaria a necessidade de intervenções sobre o MDS. Mesmo assim, como os pontos colhidos no levantamento LiDAR não são regularmente espaçados e as oclusões sempre ocorrem, ainda seria necessária alguma intervenção.

5.1.1.2. Interpolação

A interpolação preenche pixels vazios do MDS visando melhorá-lo antes da operação morfológica de fechamento. Limita-se a atuar apenas sobre os pixels vazios da imagem, deixando os não vazios inalterados. Utiliza-se de informações dos pixels vizinhos no próprio MDS, bem como na respectiva imagem Intensidade do LiDAR. A imagem Intensidade fornece mais uma informação a respeito da feição presente na imagem, permitindo decidir melhor sobre o preenchimento do pixel. A Figura 13 mostra parte da imagem intensidade.

A operação de interpolação se faz através de uma matriz 3x3 que percorre o MDS procurando por pixels sem informação (DN=0). Ao encontrar um pixel vazio no MDS, verifica-se a vizinhança deste pixel no próprio MDS, bem como na imagem Intensidade. Os valores dos pixels vizinhos ao pixel vazio no MDS informam sobre a diferença de altura entre seus vizinhos, em uma direção, e, quando esta diferença é superior a 1 metro, entende-se que não fazem parte de uma mesma feição, e o pixel é preenchido com o menor dos valores vizinhos.




FIGURA 13 – PARTE DA IMAGEM INTENSIDADE, COM RESOLUÇÃO 50cm, UTILIZADA PARA AUXILIAR A INTERPOLAÇÃO.

Já os valores da vizinhança na imagem Intensidade auxiliam na informam sobre os materiais ao redor do pixel vazio, entendendo que, se a diferença for superior a 30, este pixel não estará entre pixels de uma mesma feição. Verificam-se quatro direções, como mostrado na Figura 14, a seguir.

| | | |
|---|---|---|
| 1 | 2 | 3 |
| 4 | 0 | 5 |
| 6 | 7 | 8 |

direção Norte-Sul = comparação entre pixels 2 e 7

direção Leste-Oeste = comparação entre pixels 5 e 4

direção Sudoeste-Nordeste = comparação entre pixels 6 e 3

direção Sudeste-Noroeste = comparação entre pixels 8 e 1

FIGURA 14 – MATRIZ (3 x 3) E DIREÇÕES DE COMPARAÇÃO

O pixel é preenchido segundo a condição mostrada abaixo, que é verificada para cada uma das quatro direções.

SE, na direção avaliada, os pixels vizinhos têm diferença de altura menor que 1 metro **E** diferença de intensidade menor que 30, **ENTÃO** o pixel vazio do MDS é preenchido com o maior dos valores da vizinhança na direção que está sendo avaliada.

No caso de nenhuma das direções preencherem o pixel, tal pixel vazio do MDS é preenchido com o menor dos valores da vizinhança. A Figura 15 mostra o resultado da aplicação do filtro.




FIGURA 15 – PARTE DO MDS INTERPOLADO ANALISANDO IM. DE ALTURA E DE INTENSIDADE. AINDA HÁ PIXEL SEM INFORMAÇÃO.

5.1.1.3. Filtro Morfológico de Fechamento

A operação de fechamento na morfologia matemática consiste na utilização da operação de Dilatação seguida da operação de Erosão, nesta ordem, com a Erosão aplicada sobre o resultado da Dilatação. O objetivo de sua utilização neste trabalho é preencher as áreas de oclusão que, se preenchidas apenas com interpolações, seriam criadas superfícies inclinadas não existentes. Além disso, a operação de fechamento suaviza as bordas das edificações no MDS, além de permitir, também, o preenchimento de vazios.

A operação de Dilatação é realizada por meio de uma janela móvel 3 x 3 pixels, que percorre toda a extensão do MDS atribuindo, ao pixel central, o maior dos valores dos pixels presentes na janela. Desta forma não são criados novos valores como na interpolação, logo não possibilitando criar o efeito “dégradé” nas áreas de oclusão. Este efeito ocorreria pois, efetuando-se diversas interpolações sucessivas, criariam-se vários valores intermediários em áreas de oclusão nas bordas de edificações, aparentando paredes inclinadas. Ocorre que, sendo esta operação executada sobre todos os pixels do MDS, as edificações terão suas áreas aumentadas e, para corrigir isto, executa-se a operação de Erosão.

A operação de erosão ocorre do mesmo modo que a operação de dilatação, exceto pelo preenchimento do pixel central pelo menor dos valores da janela móvel. Assim, os excessos da dilatação são retirados. O resultado é mostrado na Figura 16.




FIGURA 16 – PARTE DO MDS APÓS OP. MORFOLÓGICA DE FECHAMENTO

5.1.1.4. Filtro Morfológico de Abertura

Durante o levantamento ALS, alguns pontos coletados pertencem a feições como a rede elétrica urbana ou muros, gerando pixels com valores altos no MDS. Na Figura 18, à esquerda, pode-se observar esta situação. Para realizar a filtragem foi realizada uma operação morfológica de abertura, pela utilização de um Elemento Estruturante 5 x 5, em forma de cruz, mostrado na Figura 17.

| | | | | |
|---|---|---|---|---|
| 0 | 0 | 1 | 0 | 0 |
| 0 | 1 | 1 | 1 | 0 |
| 1 | 1 | 1 | 1 | 1 |
| 0 | 1 | 1 | 1 | 0 |
| 0 | 0 | 1 | 0 | 0 |

FIGURA 17 – ELEMENTO ESTRUTURANTE DO FILTRO MORFOLÓGICO DE ABERTURA, 5 x 5, EM CRUZ.

A operação morfológica de abertura ocorre no sentido inverso à operação de fechamento, ou seja, realiza-se uma Erosão seguida de uma Dilatação.

O resultado da aplicação deste filtro pode ser visto na Figura 18, à direita.




FIGURA 18 – MDS COM PIXELS SOBRE FEIÇÕES COMO REDE ELÉTRICA E MUROS (ESQUERDA) E MDS FILTRADO (DIREITA)

5.1.2. MDT – Modelo Digital de Terreno

O arquivo de pontos LiDAR – utilizado para gerar o MDS – foi submetido a um algoritmo de filtragem de pontos, implementado no software livre ALDPAT (*Airborne LiDAR Data Processing and Analysis Tools*) v 1.0, da *International Hurricane Research Center*. O algoritmo em questão é um filtro morfológico progressivo, chamado *Progressive Morphological Filter*, desenvolvido por Zhang et. al. (2003), que se utiliza de um elemento estruturante que cresce gradualmente, bem como de diferentes limiares de elevação (ALDPAT 1.0, ZHANG e CUI, 2007).

O MDT foi gerado no software ENVI, projetando os pontos pertencentes ao terreno - resultado do software ALDPAT - sobre uma grade com resolução de 50cm,

5.1.3. MDSn – Modelo Digital de Superfície Normalizado

O Modelo Digital de Superfície normalizado (MDSn) é um modelo digital resultante da subtração do Modelo Digital de Superfície (MDS) pelo Modelo Digital de Terreno (MDT), conforme a equação (24) a seguir:

$$MDSn = MDS - MDT \quad (24)$$

5.2. ORTORRETIFICAÇÃO

O processo de ortorretificação da imagem foi realizado através da Transformação Projetiva, mediante um programa desenvolvido no MATLAB. A Figura 19 mostra as etapas implementadas no programa.

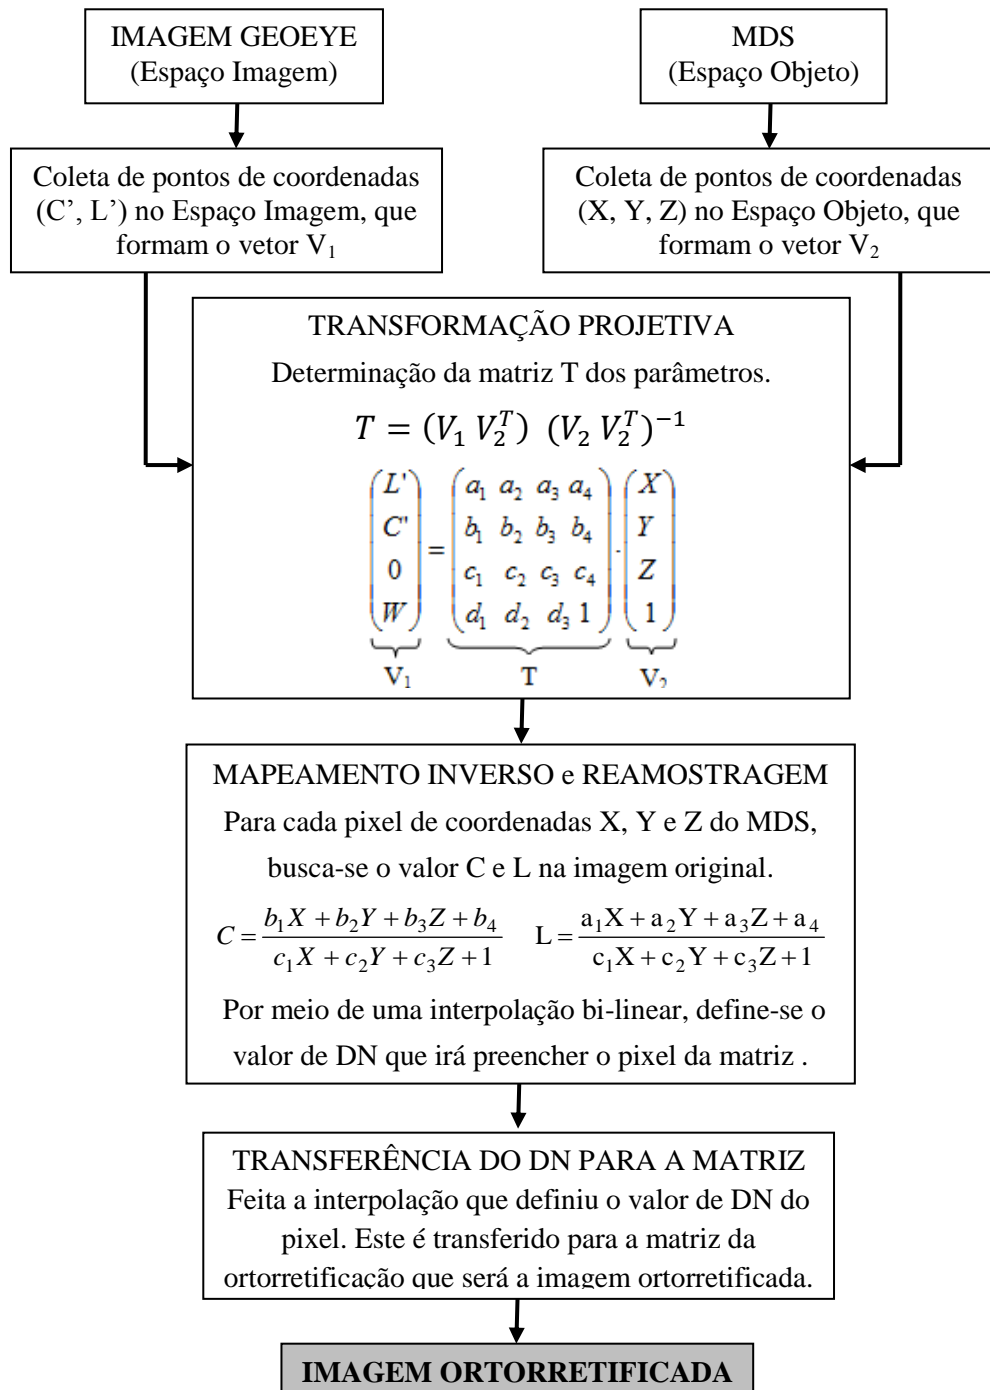


FIGURA 19 – DETALHAMENTO DA GERAÇÃO DA ORTOIMAGEM
FONTE: O autor (2011)

A ortorretificação corrige as distorções geométricas da imagem, de modo que esta se sobreponha ao MDS, fazendo com que as edificações estejam em suas verdadeiras posições. Assim, para o conjunto de feições presentes na área de estudo, é possível associar a informação espectral da imagem com a informação de altura do MDS.

A Transformação Projetiva – formada por polinômios racionais de primeira ordem – utilizada nesta pesquisa fez uso da solução direta, mediante um ajustamento pelo Método dos Mínimos Quadrados (MMQ) na forma paramétrica, assumindo-se que o MDS – espaço objeto das observações – é isento de erros. A matriz P dos pesos é matriz identidade, onde os pesos são unitários e, desta forma, assume-se que a precisão esperada para os pontos é de uma unidade de medida, no caso um pixel.

Inicialmente, os pontos de controle (PCs) e pontos de verificação (PVs) foram adequadamente distribuídos sobre a imagem, evitando criar áreas com maior densidade de pontos que as demais. Na imagem são coletadas as coordenadas – coluna e linha – dos pontos no espaço imagem. Já no MDS são coletadas as coordenadas – X , Y , Z ou E , N , h – dos pontos homólogos ao espaço objeto. Seguindo o que foi explicado no item 2.3.2.1, as coordenadas (L' , C') dos pontos de controle geram a matriz V_1 , e as coordenadas (X , Y , Z) geram a matriz V_2 , da equação 3, escrita na forma do mapeamento inverso. O mapeamento inverso consiste em encontrar as coordenadas de um ponto na imagem, a partir de suas coordenadas no terreno. A matriz T , de transformação, é calculada pela equação 6, gerando os parâmetros que relacionam os espaços objeto e imagem. Assim, de posse dos parâmetros e das coordenadas de cada ponto no espaço objeto, calcula-se, com as equações 8, a respectiva posição de cada ponto no espaço imagem.

Como os valores encontrados para as coordenadas L e C no espaço imagem nem sempre são inteiros, é necessário a reamostragem de valores de pixel para se determinar qual valor será inserido na imagem ortorretificada. Esta reamostragem é feita por meio de uma interpolação bi-linear, quando é feita a média ponderada entre valores de quatro pixels vizinhos em função distância à coordenada calculada, de modo que cada pixel vizinho dá sua contribuição ao valor final do pixel na imagem ortorretificada. Definido o valor do pixel, este é transferido para a matriz que irá compor a imagem ortorretificada. A Figura 20 esquematiza o processo.




FIGURA 20 – MAPEAMENTO INVERSO NA ORTORRETIFICAÇÃO; IMAGEM ORIGINAL, MDS E MATRIZ DA ORTORRETIFICAÇÃO POSSUEM A MESMA RESOLUÇÃO (GRADES IGUAIS)

FONTE: O autor (2011)

Gerada a imagem ortorretificada, faz-se a verificação da acurácia dos resultados através de uma Análise de Resíduos, por meio do cálculo do Erro Médio Quadrático (RMSE) dos resíduos dos pontos de verificação.

5.3. SEGMENTAÇÃO E REGRAS

De posse da imagem ortorretificada nas suas quatro bandas, adicionou-se uma quinta banda: o MDSn.

No ENVI EX abriu-se esta imagem, sendo carregadas as bandas MDSn, R e IR, respectivamente em R, G e B, para segmentação. O processo de segmentação pelo algoritmo FLSA é guiado pelos índices SL e ML – apresentados no item 2.5.3 – e seus valores foram escolhidos visando segmentar as edificações de modo que

cada edificação fosse envolvida por apenas um segmento. Esta condição era desejada no intuito de que os atributos de forma dos segmentos das edificações fossem utilizados como atributos que melhor dividiriam as amostras na construção da árvore de decisão. Assim, tendo as feições perfeitamente delineadas pelo segmento, seria possível o computador identificar os segmentos pela sua forma, assim como um analista faria.

5.3.1. Segmentação FLSA da Imagem Base

Primeiramente segmentou-se da Imagem Base com o intuito de que, com apenas essa segmentação, seja possível definir regras que serão aplicadas sobre a segmentação de toda a imagem, verificando a capacidade de generalização da regra.

Utilizou-se o segmentador FLSA nesta imagem procurando obter uma segmentação tal que as edificações fossem envolvidas por apenas um segmento, não se importando com as demais feições. Assim, por tentativa e erro, definem-se os valores dos índices SL (*Scale Level*) e ML (*Merge Level*) do segmentador FLSA que melhor segmentam as edificações.

5.3.2. Seleção de amostras para cada classe

Realizada a segmentação e definidas as classes que serão utilizadas, inicia-se a seleção dos segmentos representativos de cada classe. Procurou-se selecionar os segmentos mais puros possíveis em cada classe, evitando segmentos mistos, onde duas ou mais classes estejam inseridas.

Esta pesquisa tem uma abordagem baseada em objetos – criados pela segmentação – e, desta forma, a seleção de amostras tem uma particularidade em relação às abordagens baseadas no pixel. Isso porque na abordagem baseada em objetos, não importa se o objeto é grande ou pequeno, se engloba muitos pixels ou poucos pixels. Tendo ele sido selecionado como amostra, ele será contabilizado

como apenas uma amostra – uma edificação, por exemplo – não importa seu tamanho. Em outras palavras, numa abordagem baseada em pixels, uma amostra coletada sobre uma grande edificação contribuirá com diversos pixels representativos da classe, ao passo que, numa abordagem baseada em objetos, será contabilizado apenas mais um segmento representativo da classe.

Esta característica diferencia a abordagem baseada no pixel da abordagem baseada no objeto quanto à relação de comparação do número de amostras por classe.

5.3.3. Árvore de Decisão – Algoritmo J48 no WEKA

O algoritmo J48 disponibilizado no WEKA foi executado após as amostras terem sido coletadas para cada experimento. Devido ao fato da amostra ser pequena, foi utilizado um critério de validação chamado “*10-fold cross validation*”, o qual realiza um total de dez processos de teste e treinamento com o total de amostras fornecido. A cada vez, uma parcela aleatória de 1/10 (um décimo) da amostra é utilizada para treinamento e os outros 9/10 (nove décimos) são utilizados para testes. Os erros são calculados 10 vezes e, ao fim, calcula-se a média destes para se ter o erro total estimado (WITTEN e FRANK, 2005).

A partição da amostra em dez partes é o padrão do WEKA, sendo adotado, pois, segundo diversos estudos que realizaram testes em diferentes conjuntos de dados e com diferentes técnicas de aprendizagem, verificou-se que com 10 partições se obtinha resultados mais confiáveis (WITTEN e FRANK, 2005).

O algoritmo J48 implementado no WEKA, versão 3.4.18, possui os parâmetros de configuração citados a seguir (WITTEN e FRANK, 2005):

- *binarySplits (False)*: permite optar por partições binárias, ao invés de uma partição para cada valor possível do atributo, ao se utilizar atributos nominais. *False* é o padrão, ou seja, se não for alterado, a partição para atributos nominais será feita para cada valor possível. Como os atributos utilizados nesta pesquisa são numéricos, a partição é sempre binária, conforme fora explicado no item 2.6.2.

- *confidence Factor (0.25)*: altera o fator de confiança para a poda. Quanto menor o valor, maior a poda. O valor 0.25 (ou 25%) é o padrão, correspondendo a $z=0,69$ na Distribuição Normal Padronizada (0,69 do desvio padrão).
- *debug (False)*: opção de gerar ou não informações sobre a execução do algoritmo. *False* é o padrão, não gerando tais informações.
- *minNumObj (2)* : número mínimo de elementos para formar uma folha. O valor padrão é 2, ou seja, deve haver pelo menos dois elementos na amostra que atendem um critério de partição, podendo assim criar-se a folha.
- *reducedErrorPruning (False)*: utilize o critério *reducedErrorPruning* para realizar a poda. O padrão é *False*, de não utilizar este critério.
- *numFolds (3)*: determina a quantidade de dados usada no *reducedErrorPruning*. Uma dobra (*fold*) é utilizada para poda e as outras para o crescimento da árvore.
- *seed (1)*: cada “semente” gera um conjunto aleatório de dados para serem avaliados quando *reducedErrorPruning* é utilizado. O valor padrão é 1.
- *saveInstanceData (False)*: opção de se salvar ou não os elementos em cada folha, para visualizações. O padrão é *False*, onde não é permitida a visualização, economizando memória.
- *subtreeRaising (True)*: opção de utilizar a operação *subtreeRaising* para realizar a poda.
- *unpruned (False)*: opção de não utilizar a poda. *False* é o padrão, ou seja, utilizar-se da poda é o padrão.
- *useLaplace (False)*: opção de suavizar a contagem de folhas com base no estimador *Laplace*. Padrão é *False*.

Para esta pesquisa foram utilizados os valores padrão destes parâmetros.

5.3.4. Definição das Regras

A árvore de decisão gerada no WEKA é utilizada para extrair as regras de classificação, onde cada galho da árvore é a representação do operador booleano “E”, e cada nó é uma condição a ser satisfeita. Assim, uma regra é um conjunto de condições que um segmento deve satisfazer, simultaneamente, para pertencer a uma determinada classe.

As regras que levam às classificações referentes às edificações são utilizadas para realizar a classificação dos segmentos da Imagem Teste, ou seja, as regras definidas com a Imagem Base são aplicadas na segmentação da Imagem Teste

5.4. IDENTIFICAÇÃO (Aplicação das regras)

Definidas as regras a partir da Imagem Base, estas foram aplicadas sobre a segmentação da Imagem Teste.

5.4.1. Segmentação FLSA da Imagem Teste

Para que houvesse coerência entre a Imagem Base de coleta de amostras e a Imagem Teste de aplicação das regras, os seguintes critérios foram estabelecidos:

- A Imagem Base para coleta de amostras é complementemente inserida dentro da Imagem Teste;
- A segmentação da Imagem Teste é feita de modo que os segmentos gerados nesta sejam idênticos aos previamente gerados para coleta de amostras na Imagem Base. Esta verificação de semelhança entre segmentos deve ser feita de modo visual. Com a Imagem Base estando totalmente inserida na Imagem Teste, é possível fazer tal verificação por completo.

Nesta pesquisa foi verificado se era possível segmentar a Imagem Base e a Imagem Teste com os mesmos coeficientes *Scale Level* (SL) e *Merge Level* (ML). Para isso tomou-se o cuidado de se ter as duas imagens com a mesma abrangência espectral em todas as bandas, além dos critérios supracitados. Entretanto, para os mesmos valores de SL e ML, os segmentos gerados ainda foram diferentes.

Diante disso, a segmentação da Imagem Teste foi realizada com valores SL e ML tais que, visualmente, os segmentos gerados fossem idênticos ao da Imagem Base. A Figura 21, a seguir, mostra as duas imagens com os resultados das segmentações.




FIGURA 21 – SEGMENTAÇÃO DA IMAGEM TESTE BASEIA-SE NA SEGMENTAÇÃO DA IMAGEM BASE, UTILIZADA NA GERAÇÃO DAS REGRAS. A IMAGEM TESTE, NA REGIÃO DA IMAGEM BASE, TEM SEGMENTOS IDÊNTICOS.

5.4.2. Aplicação das Regras sobre a segmentação da Imagem Teste

Cada regra gerada referente à edificação será aplicada sobre a Imagem Teste segmentada. O resultado da aplicação da regra sobre a imagem é mostrado com os segmentos detectados pela regra mostrados na cor verde, conforme a Figura 22. A Figura 23 mostra a vetorização manual sobreposta aos segmentos identificados, possibilitando quantificar o resultado.



FIGURA 22 – APLICAÇÃO DE REGRAS NA SEGMENTAÇÃO DA IMAGEM TESTE; SEGMENTOS IDENTIFICADOS DESTACADOS NA COR VERDE




FIGURA 23 – BASE VETORIZADA SOBREPOSTA AOS SEGMENTOS IDENTIFICADOS

5.5. AVALIAÇÃO E QUANTIFICAÇÃO DOS RESULTADOS

A Base Vetorizada sobreposta aos segmentos identificados pela aplicação das regras permite a quantificação dos resultados. Assim, é possível contar o número de segmentos corretamente ou incorretamente identificados.

Uma regra que, por exemplo, tenha sido criada para identificar edificações com telhado cerâmico, poderá ter seus resultados quantificados quanto ao número de ocorrência nesta classe (acertos), bem como o número de ocorrências em outras classes (erros). Esta quantificação, em cada experimento realizado, é apresentada em uma tabela, conforme pode ser visto na Figura 57. Esta tabela é apresentada nos experimentos realizados, pois desta forma é possível se obter uma melhor compreensão da mesma.

A avaliação da acurácia dos resultados é feita por meio de dois índices. Um índice de acurácia por classe, denominado *accuracy index*, AI , conforme fora utilizado por Pouliot et. al. (2002), cuja equação é dada por

$$AI_i = \left(\frac{N-(O+C)}{N} \right) \times 100 \quad (25)$$

onde i é a classe; N é o total de edificações vetorizadas da classe; O são os erros omissão; e C são os erros de inclusão.

O outro índice utilizado é chamado Índice de Acurácia Global do experimento, GA , que consiste em dividir o total de edificações corretamente classificadas em todas as classes, pelo total de edificações da Base Cartográfica vetorizada. O total de edificações nesta base é 596.

Estes dois índices são mais bem explicados no item “7.6. Experimentos”.

6. EXPERIMENTO PRÉVIO COM BASE NO PIXEL, UTILIZANDO O CONHECIMENTO DO ANALISTA

Antes de se executar a metodologia exposta no Capítulo 5, realizou-se um experimento inicial, com base no pixel, para identificar edificações utilizando o conhecimento de que uma edificação deve possuir uma determinada altura mínima acima do solo e que edificações (telhados) apresentam baixo valor de NDVI. Sendo baseado no conhecimento prévio do analista, não necessita coleta de amostras, uma vez que a regra já é previamente definida, isto é: *Se o pixel tem valor de MSDN acima de 2,40m ($DN=240n$) e valor de NDVI abaixo de 0,62, então é Edificação.*

6.1. PIXELS COM MDSN > 2,40M E NDVI < 0,62

Adotou-se o limiar de 2,40m (dois metros e quarenta centímetros) como altura mínima para edificações. Este valor é adotado nos Códigos de Obras de vários municípios brasileiros como pé-direito mínimo para banheiros em uma residência, com os demais cômodos devendo possuir um pé-direito acima deste. Assim, se assume que nenhuma edificação terá valor menor que 2,40m, visto que o pé-direito é uma medida interna da residência – do piso ao teto – e a construção de lajes e do telhado naturalmente aumenta este valor.

Posteriormente verificou-se, por meio de uma inspeção manual na imagem, que a maioria da vegetação apresentava valor de NDVI acima de 0,62, bem como a maioria das edificações apresentavam valor de NDVI abaixo deste. Assim, empiricamente nesta imagem, assumiu-se que valor de 0,62 constitui um valor limiar entre vegetação e edificação.

A extração dos pixels com tais características se inicia a partir do momento em que se dispõe da imagem ortorretificada, juntamente com seu MDSn. Assim, de posse da imagem ortorretificada formada por cinco bandas – MDSn, B, G, R e NIR –, desenvolveu-se um programa no MATLAB para gerar uma nova imagem com as mesmas cinco bandas, mas apenas com os pixels que atendiam as condições de altura acima de 2,40m e NDVI abaixo de 0,62. O resultado desta extração é

mostrado nas Figuras 24, com a extração no MDSn, e na Figura 25, com a extração na imagem óptica RGB.




FIGURA 24 – PIXELS NO MDSn COM $MDSn > 2,40M$ E $NDVI < 0,62$




FIGURA 25 – IMAGEM RGB COM PIXELS COM $MDSn > 2,40M$ E $NDVI < 0,62$

6.2. ELIMINAÇÃO DE RUÍDOS E MELHORA DAS BORDAS NO MDSN EXTRAÍDO (FILTRO MORFOLÓGICO DE ABERTURA, 5 x 5, EM CRUZ)

A imagem gerada com a imposição das condições citadas no item anterior possui diversos pixels “soltos” na imagem, isto é, pixels que não estão conectados às edificações, mas que, atendendo às condições impostas, foram extraídos juntos com os demais. Tais pixels pertencem a feições como:

- Muros: pixels sobre muros com altura acima de 2,40m.
- Árvores: pixels que pertencem a árvores, mas que podem representar galhos ou folhas não saudáveis na copa.
- Veículos: pixels pertencentes a veículos de grande porte, com altura acima de 2,40m, como caminhões em estacionamentos e ruas.
- Feições pequenas e diversas: pixels que pertencem a feições como postes, caixas d’água, toldos, barracas, etc.

Exemplos de pixels nestas condições são mostrados nas imagens da Figura 26, a seguir.

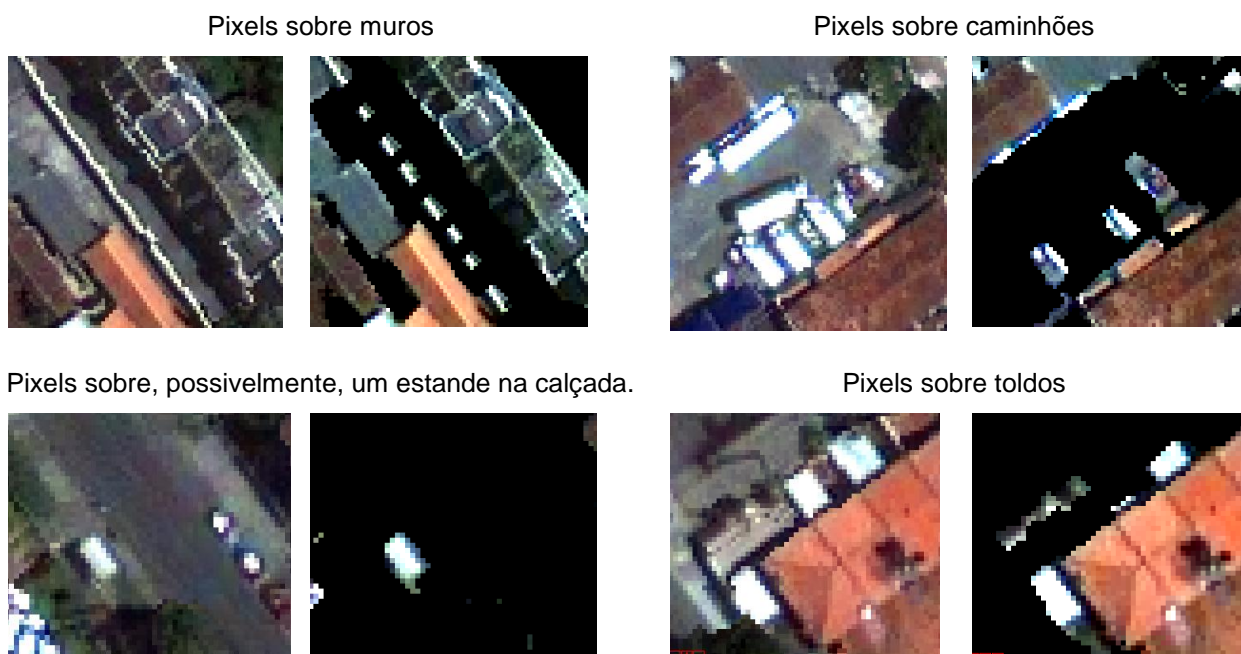


FIGURA 26 – PIXELS REMANESCENTES EM DIVERSAS FEIÇÕES

Um fato, bastante significativo, que possibilita a presença destes pixels é a diferença de data de aquisição entre a imagem GeoEye e os dados ALS. Isto porque feições presentes na imagem podem não estar mais presentes no levantamento ALS, ou vice-versa.

A eliminação destes pixels se realizou através da aplicação de um Filtro Morfológico de Abertura - de dimensões 5x5, em forma de cruz – sobre o MDSn resultante da extração inicial. O elemento estruturante é mostrado na Figura 27.

| | | | | |
|---|---|---|---|---|
| 0 | 0 | 1 | 0 | 0 |
| 0 | 1 | 1 | 1 | 0 |
| 1 | 1 | 1 | 1 | 1 |
| 0 | 1 | 1 | 1 | 0 |
| 0 | 0 | 1 | 0 | 0 |

FIGURA 27 – ELEMENTO ESTRUTURANTE DO FILTRO MORFOLÓGICO DE ABERTURA, 5 x 5, EM CRUZ.

A aplicação deste filtro também contribui para regularizar as bordas das edificações, conforme pode ser visto na Figura 28, a seguir.




FIGURA 28 – MELHORA DAS BORDAS DAS EDIFICAÇÕES

6.3. EXTRAÇÃO DOS PIXELS DAS BANDAS DO VISÍVEL SEGUNDO O MDSN MELHORADO

Até o momento, o MDSn foi preparado para conter apenas os pixels com altura acima de 2,40m e NDVI abaixo de 0,62. A seguir foi aplicado um filtro morfológico para eliminação de pixels que não pertenciam a edificações, devido suas posições não coerentes, bem como para melhoria nas bordas das edificações.

Agora a melhoria no MDSn deve se expandir às demais bandas B, G, R e NIR. Para isso, um programa no MATLAB foi desenvolvido para ler o MDSn melhorado e buscar seus pixels correspondentes nas demais bandas. Os resultados são mostrados nas Figuras 29 e 30, a seguir.




FIGURA 29 – PIXELS NO MDSn COM $MDSn > 2,40M$ E $NDVI < 0,62$, REMANESCENTES APÓS APLICAÇÃO DO FILTRO




FIGURA 30 – PIXELS NA IMAGEM OPTICA COM $MDSn > 2,40M$ E $NDVI < 0,62$, REMANESCENTES APÓS APLICAÇÃO DO FILTRO

6.4. SEGMENTAÇÃO FLSA

Tendo a imagem sido preparada nas suas cinco bandas, esta é submetida à segmentação FLSA, gerando os segmentos de edificação, conforme se observa na Figura 31.



FIGURA 31 – SEGMENTAÇÃO FLSA NA IMAGEM COM MDSN > 2,40M E NDVI < 0,62 E FILTRADA COM FILTRO MORFOLÓGICO DE FECHAMENTO

6.5. RESULTADO DO EXPERIMENTO PRÉVIO

Os segmentos gerados neste experimento prévio são confrontados com a base vetorizada, de modo que se possa quantificar o número de edificações identificadas. Na Figura 32, a seguir, os segmentos resultantes deste experimento preenchem os segmentos da base vetorizada superposta. Verificou-se que foram identificadas 534 edificações das 596 existentes, o que corresponde a 89,6% das edificações identificadas.




FIGURA 32 – SEGMENTOS RESULTANTES DO EXPERIMENTO, COM A BASE VETORIZADA SUPERPOSTA

6.5.1. Análise do Resultado

A inserção do conhecimento do analista, diretamente sobre os pixels, apresentou bom resultado, visto que os pixels remanescentes pertencem às edificações. Ao final, foram identificadas 534 edificações das 596 existentes (89,6%).

Assim, 62 edificações não foram identificadas pelo fato do alto valor de NDVI de alguns telhados mais escuros. Também se observou que o filtro em cruz melhorou as bordas das edificações e retirou os pixels remanescentes após a primeira filtragem pela altura e o NDVI. Entretanto, juntamente com estes pixels remanescentes, eliminou pixels de algumas pequenas edificações.

7. RESULTADOS

Nesta seção são apresentados os resultados da pesquisa, conforme a metodologia apresentada no Capítulo 5.

7.1. MDS – MODELO DIGITAL DE SUPERFÍCIE

O Modelo Digital de Superfície, MDS, mostrado na Figura 33, foi obtido após a projeção dos pontos ALS em grade de 50cm de resolução, a interpolação, e operação morfológica de fechamento.



FIGURA 33 – MDS - MODELO DIGITAL DE SUPERFÍCIE

7.1.1. Filtro Morfológico de Abertura aplicado ao MDS

Na banda referente ao MDS, há a presença de pontos coletados sobre feições como a rede elétrica e muros. Tais pixels irão, posteriormente, alterar os

valores dos atributos de média de altura do MDSn (AVGBAND) e valor máximo de altura (MAXBAND). Isso ocorre visto que, durante a segmentação, estes pixels são facilmente inseridos dentro de um segmento maior, porque mesmo que possuam valores digitais altos em relação aos seus vizinhos, sua pequena área facilita a fusão.

Uma vez inseridos dentro de segmentos maiores, os valores destes atributos se elevam, não sendo coerentes com segmentos ao nível do solo como Gramados e Pavimentos. Isso causa erros de classificação, pois um segmento de Gramado pode ser facilmente confundido com um segmento de Árvore, e um segmento de Pavimento cimentado ser confundido com uma Edificação de telhado de fibrocimento. Esta situação é mais grave nos segmentos pequenos, quando um valor muito elevado de altura não consegue ser “diluída” em muitos pixels de baixo valor de altura. O resultado da aplicação do filtro é mostrado na Figura 34, a seguir.



FIGURA 34 – MDS APÓS APLICAR O FILTRO MORFOLÓGICO DE ABERTURA

A filtragem, como descrita no item 6.2, não eliminou todos os pixels altos, mas diminuiu a ocorrência destes. Assim, estes pixels agora exercem pouca influência no valor médio de altura de um segmento (AVGBAND), mas ainda alteraram o valor do atributo de máxima de altura do segmento (MAXBAND), pois a ocorrência de apenas

um pixel de alto valor de altura dentro do segmento elevou o valor deste atributo. Em outras palavras, a filtragem contribuiu significativamente no ajuste do valor médio de altura do segmento, mas não teve influência no valor máximo de altura deste.

7.2. MDT – MODELO DIGITAL DE TERRENO

O Modelo Digital de Terreno, MDT, mostrado na Figura 35, a seguir, foi obtido utilizando o filtro morfológico do software ALDPAT. Este filtro foi escolhido empiricamente dentre os demais filtros disponíveis no software. O filtro morfológico obteve um bom resultado para o propósito da pesquisa, visto que eliminou os pixels pertencentes às edificações de modo que a diminuição do MDS pelo MDT gerou o MDSn com edificações de alturas coerentes com a realidade. Assim, as pequenas alturas nos pixels localizados onde antes eram edificações não eram significativas, não comprometendo o MDSn.




FIGURA 35 – MDT - MODELO DIGITAL DE TERRENO

7.3. MDSn – MODELO DIGITAL DE SUPERFÍCIE NORMALIZADO

Subtraindo o MDT do MDS se obtém o MDSn, mostrado na Figura 36. Os valores dos pixels do MDSn foram multiplicados por 100 (cem), de modo que houvesse compatibilidade de escala de valores dos pixels do MDSn com os valores de pixels das demais bandas espectrais de 11 bits, de 2048 valores digitais. Esta compatibilidade permite que a banda do MDSn tenha influência na segmentação. Deste modo, conseqüentemente, as alturas das edificações foram representadas em centímetros, não mais em metros, de modo que o valor do pixel igual a 1950 corresponde a 1950 cm de altura, por exemplo.



FIGURA 36 – MDSn - MODELO DIGITAL SUPERFÍCIE NORMALIZADO

7.4. ORTORRETIFICAÇÃO

Foram coletados 14 pontos de controle (PCs) e 8 pontos de verificação (PVs) devidamente distribuídos sobre a imagem GeoEye – espaço imagem – e o MDS – espaço objeto – de modo que os efeitos das distorções da imagem sejam minimizados. Nas Figuras 37 e 38, os PVs estão representados como pontos vermelhos e os PCs estão representados por cruzes amarelas.

No MATLAB foi desenvolvido um programa para realizar a ortorretificação pela Transformação Projetiva. No Apêndice A apresenta-se o relatório gerado pelo algoritmo, onde são mostrados, tanto para os PCs quanto para os PVs, os valores de coordenadas obtidas com o modelo matemático, seus respectivos desvios, o RMSE (*Root Mean Square Error*, ou Erro Médio Quadrático) nas direções E e N, e o RMSE resultante. A imagem ortorretificada pode ser vista na Figura 39.



FIGURA 37 – DISTRIBUIÇÃO DOS PONTOS DE CONTROLE (PCs) E PONTOS DE VERIFICAÇÃO (PVs) NO ESPAÇO IMAGEM: ● PCs ✦ PVs




FIGURA 38 – DISTRIBUIÇÃO DE PONTOS DE CONTROLE (PCs) E PONTOS DE VERIFICAÇÃO (PVs) NO ESPAÇO OBJETO: ● PCs ✚ PVs



FIGURA 39 – IMAGEM ORTORRETIFICADA

Os valores de RMSE dos pontos de verificação atestam o resultado da ortorretificação com a Transformação Projetiva, visto que o RMSE na direção x , correspondente a E , foi de 0,72 pixels (0,36m) e na direção y , correspondente a N , foi de 0,76 pixels (0,38m). O valor final de RMSE foi de 1,05 pixels, ou 0,53 metros. Desta forma, os erros ocasionados pelas distorções da imagem foram reduzidos, permitindo que a imagem se ajustasse ao MDSn, o que é fundamental para a etapa de segmentação.

7.5. SEGMENTAÇÃO FLISA

A abordagem baseada em objetos consiste em trabalhar sobre regiões da imagem, obtidos com a aplicação de métodos de segmentação. Esta abordagem difere da abordagem baseada no pixel – unidade básica da imagem – pois agrupa pixels conforme sua semelhança espectral e, neste trabalho, também considera questões geométricas. Assim, para o melhor desempenho da classificação da imagem e, conseqüentemente, melhor identificação das edificações, é fundamental se obter uma segmentação adequada, ou seja, uma segmentação que resulte em apenas um segmento por feição. Em outras palavras, cada segmento correspondendo a uma feição específica, sem misturas e sem supersegmentação.

Esta condição ideal é muito difícil de ser alcançada, ainda mais em um ambiente urbano, onde existem feições muito diversificadas, tanto espectralmente quanto geometricamente. Desta forma, a segmentação da imagem gerou segmentos em três situações possíveis: (1) englobando perfeitamente uma determinada feição, sem misturas; (2) englobando mais de uma feição, da mesma classe (sem mistura, mas agrupando feições) ou de diferentes classes (com mistura); (3) englobando parte de uma feição ou, em outras palavras, mais de um segmento representando uma única feição. Exceto a primeira situação, que é ideal, as duas últimas impõem dificuldades na classificação.

No caso de englobar mais de uma feição de uma mesma classe, a classificação pode ser acertada por não haver mistura espectral, entretanto, no caso de edificações, convém que isso não ocorra por se tratarem de unidades independentes, devendo ser tratados como segmentos distintos. Quando o

segmento engloba feições de classes diferentes, a classificação fica comprometida devido à mistura espectral, dificultando tanto a sua identificação posterior quanto a escolha deste segmento como amostra da classe. Este problema ocorre em feições distintas que estejam próximas e sejam espectralmente similares, tal como uma edificação de telhado cerâmico escuro próximo a uma árvore de tonalidade verde escura. A utilização do MDSn na segmentação tende a evitar tais misturas, entretanto, nos casos onde a edificação e a árvore possuem alturas parecidas, esta vantagem não ocorre por serem similares também no MDSn.

Nos casos em que há mais de um segmento representando uma mesma feição, garante-se a pureza espectral do segmento, mas compromete-se a geometria da feição. A possibilidade de classificação por atributos geométricos é uma característica importante da classificação baseada em objetos, pois capacita a classificação de feições de maneira mais próxima da classificação feita pelo ser humano. Esta sobresegmentação ocorreu em telhados de duas ou mais águas devido à diferente incidência de luz solar, de modo que tanto a face (água) mais iluminada quanto a menos iluminada geraram segmentos distintos. Este problema também ocorreu em edificações com telhados arquitetonicamente mais complexos, possuindo diversas águas ou ainda com estruturas diferenciadas, tais como trapeiras. Telhados com trapeiras apresentaram alta sobresegmentação, com diversos segmentos sobre os mesmos, inviabilizando qualquer caracterização geométrica adequada. A ocorrência de telhados diferentes em uma mesma edificação cria, quase que inevitavelmente, segmentos distintos sobre uma mesma edificação. O mesmo ocorre quando existem telhados construídos em épocas distintas, sendo um mais novo que o outro.

Ainda na segmentação, mas com respeito aos atributos dos segmentos gerados, verificou-se que o software ENVI EX, utilizado nesta pesquisa, calcula atributos de textura apenas para a primeira banda da imagem. Assim, para avaliar as texturas nas várias bandas, foi aumentada a quantidade de experimentos, de modo que cada tipo de experimento considerasse os atributos de textura em uma das bandas. Não foi possível gerar um experimento único com todos os atributos de banda devido ao fato de, a cada segmentação, mesmo que fossem gerados polígonos muito semelhantes, estes não eram iguais e apresentavam numeração diferenciada.



FIGURA 40 – IMAGEM TESTE, MOSTRANDO A IMAGEM BASE INSERIDA NO POLÍGONO AMARELO



FIGURA 41 – IMAGEM BASE, UTILIZADA PARA GERAÇÃO DE REGRAS




FIGURA 42 – MDSn DA IMAGEM BASE, UTILIZADA PARA GERAÇÃO DE REGRAS




FIGURA 43 – BANDAS MDSn, R e NIR CARREGADAS EM R, G, e B PARA A SEGMENTAÇÃO.




FIGURA 44 – SEGMENTAÇÃO SOBRE IMAGEM RGB (SL=66 E ML=70) DA IMAGEM BASE




FIGURA 45 – SEGMENTAÇÃO SOBRE O MDSn (SL=66 E ML=70) DA IMAGEM BASE



FIGURA 46 – SEGMENTAÇÃO SOBRE IMAGEM TESTE (SL=43 E ML=70)




FIGURA 47 – SEGMENTAÇÃO SOBRE MDSn DA IM. TESTE (SL=43 E ML=70)

7.5.1. Áreas com Duplo Mapeamento

A presença de edificações altas em imagens urbanas frente à dimensão submétrica do pixel, juntamente com a inclinação da visada do sensor na tomada da imagem, faz com que fachadas destas edificações sejam visíveis, com o topo destas edificações bastante deslocados e gerando regiões de oclusão na imagem.

Para corrigir isso, um MDS se faz necessário, de modo a posicionar corretamente o topo das edificações, além de corrigir o efeito da variação do relevo. Ocorre que, estando os pixels do topo das edificações devidamente posicionados, a área onde este topo deslocado estava anteriormente é preenchido ainda com os mesmos valores de pixel, dando a impressão de haver uma repetição de parte do topo da edificação. Isto é conhecido como “duplo mapeamento”. Apesar das edificações da imagem utilizada nesta pesquisa não serem muito altas, tal problema ocorreu em algumas edificações, como as mostradas na Figura 48, a seguir.



FIGURA 48 – OCORRÊNCIAS DE DUPLO MAPEAMENTO

Para retirar este efeito, costuma-se aplicar uma máscara de oclusão na imagem, que consiste em identificar as áreas e substituir tais pixel por pixel de valor 0 (zero), pois se trata de área sem informação. Neste trabalho esta máscara não foi aplicada, visto que a segmentação é feita utilizando o MDSn como uma das bandas, de modo que tais áreas de duplo mapeamento não se misturam aos segmentos das edificações. Assim, tais áreas são envolvidas por um segmento separado, com baixo valor para o atributo de altura, conforme mostrado na Figura 49, a seguir.




FIGURA 49 – SEGMENTAÇÃO EM ÁREA DE DUPLO MAPEAMENTO – RGB

Da mesma forma, apresentam-se na Figura 50, os mesmo segmentos sobre o MDSn.




FIGURA 50 – SEGMENTAÇÃO EM ÁREA DE DUPLO MAPEAMENTO – MDSn

Nota-se que as áreas de duplo mapeamento ocorrem em duas situações: (1) sobre o terreno; (2) sobre outra edificação de altura diferente. Na primeira situação a área de duplo mapeamento será naturalmente mais uma área de solo; na segunda situação, o duplo mapeamento poderá ser considerado uma edificação à parte, mas ainda uma edificação. A situação mais prejudicial seria caso uma área de duplo mapeamento fosse projetada sobre outra feição vizinha de mesma altura, podendo assim ser envolvida pelo mesmo segmento que envolve a edificação em sua posição correta. Apesar disso, tal situação não ocorreu e o duplo mapeamento não gerou problemas na metodologia desenvolvida.

7.6. EXPERIMENTOS

Com a imagem GeoEye ortorretificada composta de 5 (cinco) bandas – MDSn, B, G, R, NIR – realizou-se uma série de experimentos, apresentados no Quadro 07. Visto que software ENVI EX, ao segmentar uma imagem, coleta os atributos de Textura apenas para a primeira banda da imagem, foi necessário realizar experimentos para cada uma das bandas como primeira banda da imagem. Deste modo, cada experimento considera atributos de textura em uma das bandas da imagem.

Os experimentos são denominados por 1, 2, 3, 4 e 5. São eles:

- Experimentos 1: têm a banda B, azul do visível, como primeira banda da imagem, de modo que os atributos de textura são relativos à banda B;
- Experimentos 2: têm a banda G, verde do visível, como primeira banda da imagem, de modo que os atributos de textura são relativos à banda G;
- Experimentos 3: têm a banda R, vermelho do visível, como primeira banda da imagem, de modo que os atributos de textura são relativos à banda R;
- Experimentos 4: têm a banda NIR, infravermelho próximo, como primeira banda da imagem, e os atributos de textura são relativos à banda NIR;
- Experimentos 5: têm a banda MDSn, referente ao Modelo Digital de Superfície normalizado, como primeira banda da imagem, de modo que os atributos de textura são relativos à banda do MDSn;

Cada um destes experimentos possui três subdivisões, de acordo a divisão de classes de tipos de edificação. São as subdivisões:

- Subdivisão A: considera quatro classes chamadas “Telhado de Fibrocimento Claro”, “Telhado de Fibrocimento Escuro”, “Telhado Cerâmico Claro” e “Telhado Cerâmico Escuro”;
- Subdivisão B: considera duas classes chamadas “Telhado Cerâmico” e “Telhado Fibrocimento”;

- Subdivisão C: considera apenas uma classe chamada “Edificação”.
- O Quadro 07 mostra a divisão dos experimentos e classes consideradas.

| Experimento | Subdivisão do experimento | Classes consideradas | |
|----------------------------------|---------------------------|---|---|
| Experimentos 1 Banda 1 = B | 1-A | Telha Fibrocimento Claro Telha Fibrocimento Escuro | Telha Cerâmico Claro Telha Cerâmico Escuro |
| | 1-B | Telha Fibrocimento Telha Cerâmica | |
| | 1-C | Edificação | |
| Experimentos 2 Banda 1 = G | 2-A | Telha Fibrocimento Claro Telha Fibrocimento Escuro | Telha Cerâmico Claro Telha Cerâmico Escuro |
| | 2-B | Telha Fibrocimento Telha Cerâmica | |
| | 2-C | Edificação | |
| Experimentos 3 Banda 1 = R | 3-A | Telha Fibrocimento Claro Telha Fibrocimento Escuro | Telha Cerâmico Claro Telha Cerâmico Escuro |
| | 3-B | Telha Fibrocimento Telha Cerâmica | |
| | 3-C | Edificação | |
| Experimentos 4 Banda 1 = NIR | 4-A | Telha Fibrocimento Claro Telha Fibrocimento Escuro | Telha Cerâmico Claro Telha Cerâmico Escuro |
| | 4-B | Telha Fibrocimento Telha Cerâmica | |
| | 4-C | Edificação | |
| Experimentos 5 Banda 1 = MDSn | 5-A | Telha Fibrocimento Claro Telha Fibrocimento Escuro | Telha Cerâmico Claro Telha Cerâmico Escuro |
| | 5-B | Telha Fibrocimento Telha Cerâmica | |
| | 5-C | Edificação | |

QUADRO 07 – EXPERIMENTOS REALIZADOS

Foram considerados 43 atributos – 42 calculados na segmentação, mais o atributo CLASSE – em cada experimento. Com os atributos, foram geradas as árvores de decisão de onde foram extraídas as regras que especificam cada classe. As árvores de decisão e suas respectivas Matrizes de Confusão, geradas no Weka, são mostradas no Apêndice B.

A Figura 51 mostra a localização das amostras dos objetos na imagem, realizada para os Experimentos A, com 4 classes de edificação. Na Figura 52 tem-se esta mesma localização mostrada apenas com os segmentos selecionados, facilitando a visualização. Do mesmo modo tem-se a Figura 53, com os segmentos para os Experimentos B, em que não há distinção entre telhado claro e escuro, apenas entre Cerâmico e Fibrocimento. Já a Figura 54 mostra os segmentos para os Experimentos C, em que há apenas uma classe para todas as edificações.




FIGURA 51 – EXEMPLO DE ESCOLHA DE AMOSTRAS PARA EXPERIMENTOS DA SUBDIVISÃO X-A, SOBRE A IMAGEM ÓPTICA

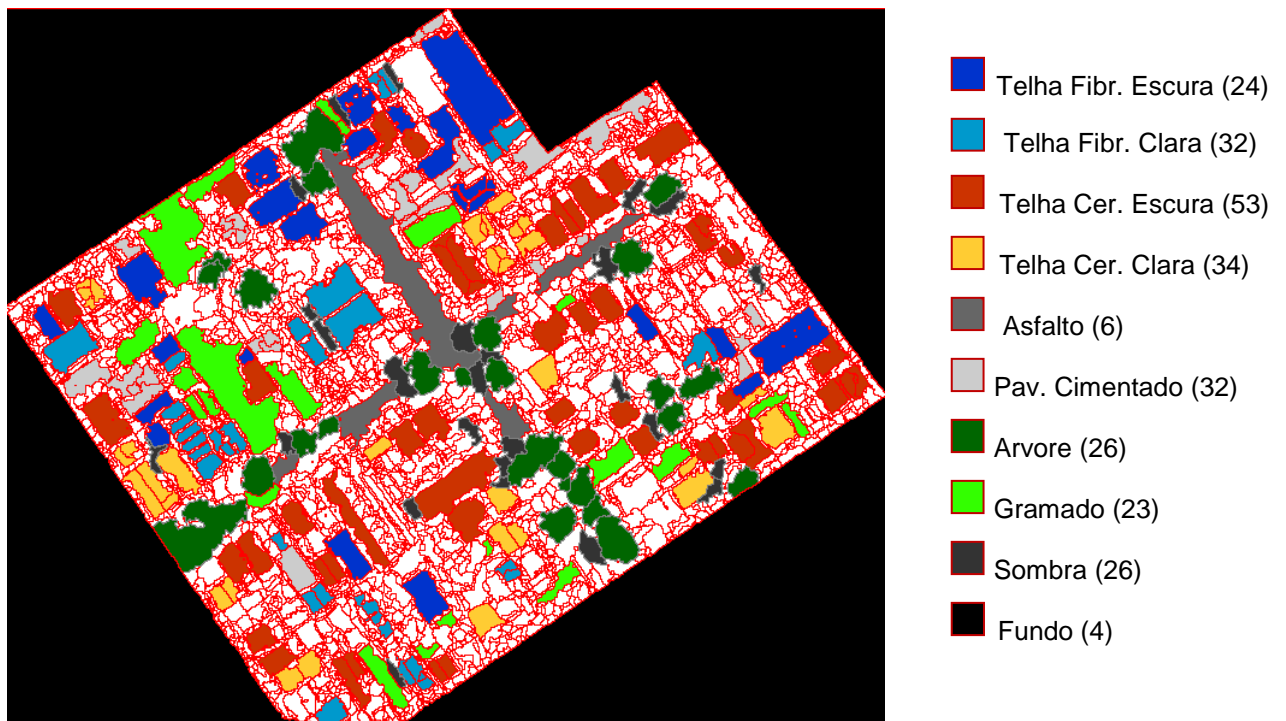


FIGURA 52 – EXEMPLO DE ESCOLHA DE AMOSTRAS PARA EXPERIMENTOS DA SUBDIVISÃO X-A; LEGENDA COM OS NOMES DAS CLASSES E AS RESPECTIVAS QUANTIDADES DE AMOSTRAS



FIGURA 53 – EXEMPLO DE ESCOLHA DE AMOSTRAS PARA EXPERIMENTOS DA SUBDIVISÃO X-B; LEGENDA COM OS NOMES DAS CLASSES E AS RESPECTIVAS QUANTIDADES DE AMOSTRAS




FIGURA 54 – EXEMPLO DE ESCOLHA DE AMOSTRAS PARA EXPERIMENTOS DA SUBDIVISÃO X-C; LEGENDA COM OS NOMES DAS CLASSES E AS RESPECTIVAS QUANTIDADES DE AMOSTRAS

Os Experimentos 1 – ou seja, 1-A, 1-B e 1-C – têm seus resultados mostrados na seguinte sequência: (a) Tabela de regras do experimento (referentes à edificação); (b) Figuras da aplicação das regras; (c) Tabela de quantificação dos resultados; (d) Análise dos resultados.

Nos demais experimentos não são mostradas as figuras referentes à aplicação das regras (item b).

A Figura 55 mostra um exemplo de tabela de regras. São três colunas: a primeira coluna “REGRA” mostra o número da regra; a segunda coluna “DESCRIÇÃO DA REGRA” mostra a descrição da regra em si; e a terceira coluna “WEKA” mostra, através de dois valores, o desempenho da regra “4” (exemplo), referente à classe “Telha Fibrocimento Escuro” na árvore de decisão, frente à amostra coletada para esta classe. O valor 18 corresponde ao número de acertos de classificação e o valor 1 é o número de erros de classificação, mas referente apenas às amostras coletadas para cada classe, pois a regra ainda não fora aplicada na segmentação da imagem Teste. Estes dois valores dão uma idéia da capacidade de detecção da regra antes de aplicá-la na segmentação da imagem Teste.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|---|------------|
| 1 | ... | |
| ... | ... | |
| 4 | Se 208.374258 < MDSn <= 791.996119 e B > 260.64486 e 110.645985 < R <= 201.451197 então Telha_Fibr_Escuro | (18.0/1.0) |

FIGURA 55 – EXEMPLO DE TABELA DAS REGRAS DOS EXPERIMENTOS

A Figura 56 mostra um exemplo de aplicação das regras (item b) sobre a segmentação da imagem Teste. A aplicação das regras foi feita no software gvSIG, pesquisando os atributos dos segmentos que atendiam a regra. Os segmentos encontrados são mostrados na cor verde. Sobre estes foram postas as camadas referentes às edificações da base vetorizada, de modo a quantificar o resultado.

Observou-se que, ao se aplicar a regra na segmentação da imagem Teste, ocorre que algumas edificações são parcialmente detectadas, isto é, não ocorre o preenchimento total da edificação representada na base vetorizada, como pode ser observado nos exemplos mostrados na Figura 57.

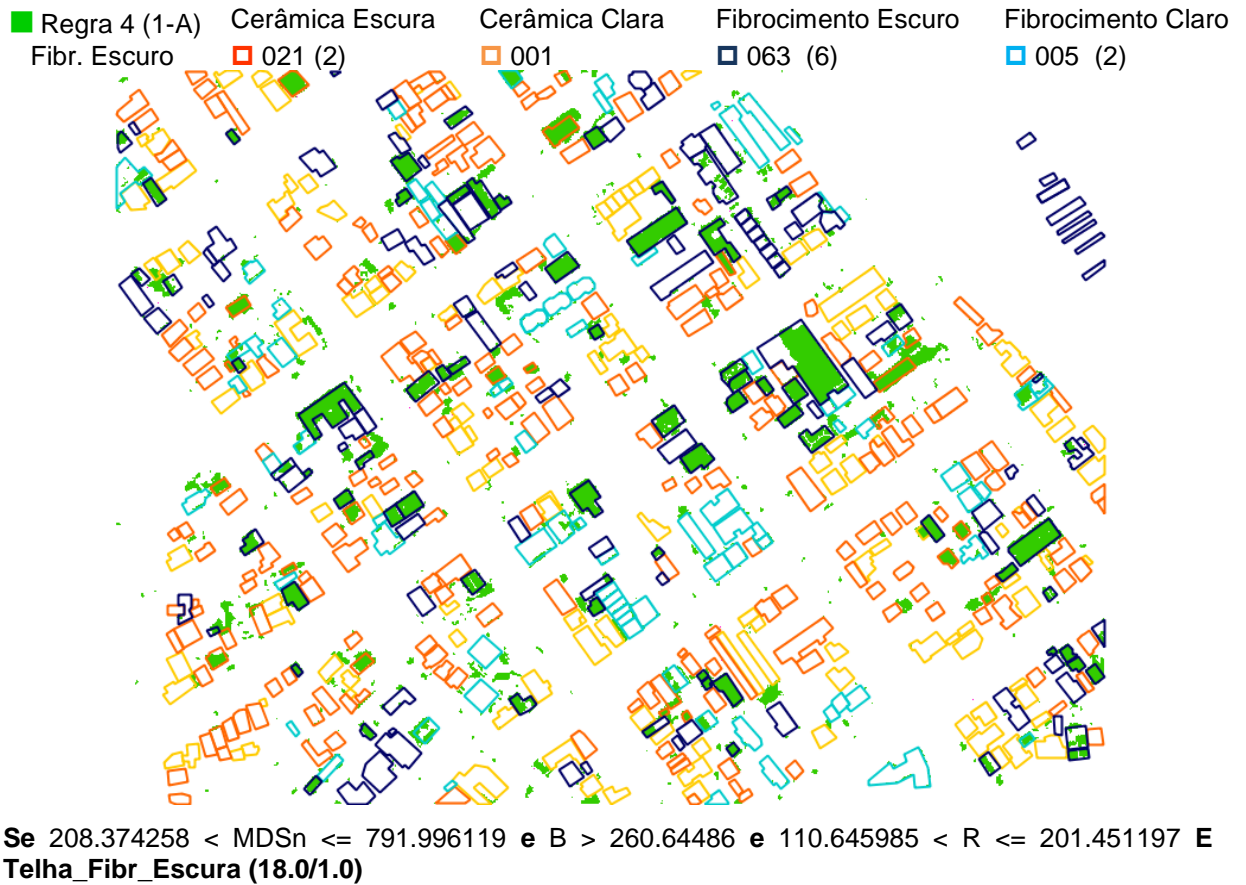


FIGURA 56 – EXEMPLO DE APLICAÇÃO DAS REGRAS

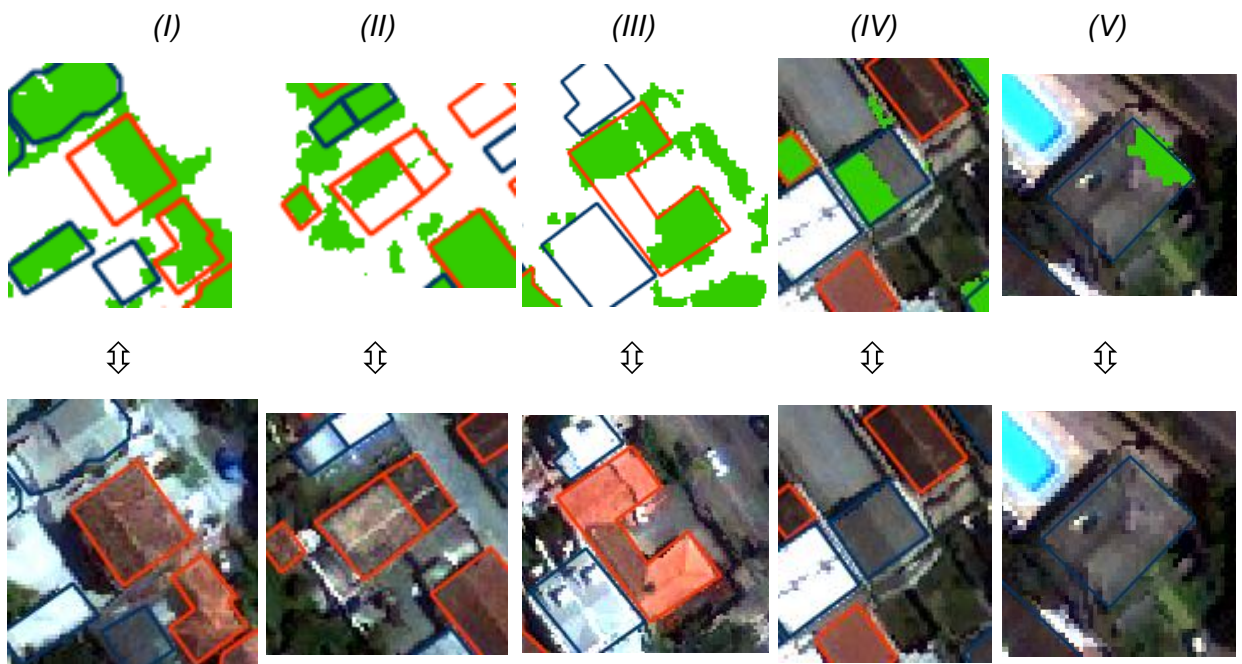


FIGURA 57: EDIFICAÇÕES PARCIALMENTE DETECTADAS

Observando tal ocorrido, percebeu-se que isto se deve aos seguintes motivos:

- **Subjetividade da definição de tonalidade:** a definição de tonalidade clara ou escura é subjetiva, sendo totalmente dependente da percepção do analista, que coleta amostras conforme o seu critério de classificação, do mesmo modo como define a própria base vetorizada ao definir as classes de casa edificação. O computador, por sua vez, realiza a classificação mediante as características dos segmentos, sendo que os atributos espectrais serão considerados conforme a média dos valores dos pixels pertencentes ao segmento. A percepção de tonalidade do analista é inferior e pode ser conflitante com a percepção quantitativa do computador.
- **Regras complementares referentes a uma mesma classe:** a árvore de decisão gera mais de uma regra referente a uma mesma classe, de modo que tais regras tendem a ser complementares na detecção do telhado de uma mesma edificação. As diferenças quanto à incidência solar entre diferentes águas dos telhados, bem como ao SEU estado de conservação, são fatores que tornam possível a ocorrência de duas classes em um telhado de uma mesma edificação. Somado a isto tem-se a vetorização realizada, na qual cada edificação é representada por apenas um polígono, não distinguindo pela tonalidade do telhado, mas apenas pelo seu material. Assim, uma determinada regra 1 de uma determinada classe “X” pode detectar uma parte do telhado, e outra regra 2, da mesma classe “X”, detectar outra parte.
- **Erros de classificação:** outro motivo deve-se, simplesmente, a erros de classificação da regra quanto ao tipo de material.

Esta detecção parcial das edificações influencia na quantificação dos resultados, de modo que foi utilizado o critério de contar como edificação detectada aquelas tais em que mais da metade do polígono tenha sido preenchido. Deste modo, na Figura 56, os casos I, II, III e IV são contabilizados, mas o caso V não é contabilizado.

Tal consideração não impede que, ao se realizar a contagem das edificações, não ocorra uma sobreposição de resultados, quando uma mesma edificação é contabilizada em mais de uma regra, tanto como acerto quanto como erro. Sendo assim, para maior confiabilidade dos resultados, preferiu-se indicar,

também, o número de edificações em que houve detecção parcial em cada regra. Tais valores são mostrados entre parênteses nas tabelas de resultados dos experimentos, mas não são considerados nos cálculos de acurácia dos resultados.

Esta quantificação é mostrada acima da Figura 55, onde se pode ver que a regra exemplificada encontrou 21 edificações da classe Telha Cerâmica Escura (sendo 2 detectadas com 50% de preenchimento), 1 edificação da classe Telha Cerâmica Clara, 63 edificações da classe Fibrocimento Escuro (sendo 6 detectadas com 50% de preenchimento), e 5 edificações para a classe Fibrocimento Claro (sendo 2 detectadas com 50% de preenchimento). Abaixo da figura descreve-se a regra.

Aplicadas todas as regras, os resultados foram armazenados em uma tabela, conforme está exemplificado na Figura 58, a seguir.

| Regra | | Cer. Escura: 229 | | Cer. Clara: 128 | | Fib. Escuro: 156 | | Fib. Claro: 83 | | Corretos | | Incorretos | |
|-------------------|--------------|------------------|------|-----------------|------|------------------|------|----------------|------|----------|------|------------|------|
| 1 | Cer. Escura | 9 | (4) | 0 | 0 | 9 | (4) | 0 | 0 | 9 | (4) | 9 | (4) |
| 2 | Fibr. Escura | 13 | (2) | 0 | 0 | 19 | 0 | 0 | 0 | 19 | 0 | 13 | (2) |
| 3 | Cer. Escura | 145 | (11) | 1 | 0 | 17 | (1) | 0 | 0 | 145 | (11) | 18 | (1) |
| 4 | Fibr. Escuro | 21 | (2) | 1 | 0 | 63 | (6) | 5 | (2) | 63 | (6) | 27 | (4) |
| 5 | Fibr. Claro | 2 | (1) | 0 | 0 | 13 | (4) | 4 | (1) | 4 | (1) | 15 | (5) |
| 6 | Cer. Escura | 7 | (4) | 13 | (7) | 1 | (1) | 0 | 0 | 7 | (4) | 14 | (8) |
| 7 | Cer. Clara | 1 | (1) | 8 | (5) | 0 | 0 | 0 | 0 | 8 | (5) | 1 | (1) |
| 8 | Cer. Escura | 8 | (5) | 16 | (7) | 0 | 0 | 1 | 0 | 8 | (5) | 17 | (7) |
| 9 | Cer. Clara | 8 | (3) | 63 | (10) | 0 | 0 | 0 | 0 | 63 | (10) | 8 | (3) |
| 10 | Fibr. Claro | 0 | 0 | 6 | (5) | 8 | (6) | 42 | (8) | 42 | (8) | 14 | (11) |
| 11 | Cer. Clara | 0 | 0 | 7 | (7) | 3 | (2) | 12 | (8) | 7 | (7) | 15 | (10) |
| 12 | Fibr. Claro | 0 | 0 | 0 | 0 | 0 | 0 | 3 | 0 | 3 | 0 | 0 | 0 |
| Identificados | | 214 | (33) | 115 | (41) | 133 | (24) | 67 | (19) | 378 | | 63.42% | |
| Corretos | | 169 | (24) | 78 | (22) | 82 | (6) | 49 | (9) | 378 | | 63.42% | |
| Incorretos | | 45 | (9) | 37 | (19) | 51 | (18) | 18 | (10) | 151 | | (56) | |
| Não Identificados | | 15 | | 13 | | 23 | | 16 | | | | | |

FIGURA 58 – EXEMPLO DE TABELA DOS RESULTADOS DOS EXPERIMENTOS

Esta figura mostra uma tabela onde se apresenta a quantificação dos resultados da aplicação de cada regra. As linhas correspondem às regras e as colunas correspondem às classes. A Regra 4, em destaque, refere-se à classe Fibrocimento Escuro e classifica corretamente 63 segmentos nesta classe. As células de cor cinza na tabela correspondem aos acertos (corretos), ou seja, quando a regra referente a uma determinada classe classifica corretamente segmentos na classe. Os demais valores – 21, 1 e 5 – correspondem a erros (incorretos), ou seja, segmentos identificados pela regra de Fibrocimento Escuro que na verdade pertencem a outras classes.

Os principais valores da tabela estão identificados por círculos numerados, de 1 a 10, e são explicados a seguir:

① **Identificados**: total de objetos, da classe da respectiva coluna, encontrados pelas regras, correta ou incorretamente. Soma todos os valores da coluna.

② **Corretos (linha)**: total de objetos identificados pelas regras que correspondem à mesma classe da coluna. É o total de acertos na classe, onde as células de cor cinza são somadas. No caso da classe Cerâmica Escura, o total de acertos soma os valores 9, 145, 7 e 8, num total de 169, tendo sido identificados pelas Regras 1, 3, 6 e 8, respectivamente.

③ **Incorretos (linha)**: total de objetos identificados erroneamente, ou seja, identificados por regras que não correspondem à mesma classe da coluna. É o somatório das células que não são da cor cinza. No caso da classe Cerâmica Escura, este total é a soma dos valores 13, 21, 2, 1, 8, 0, 0, e 0 que foram identificados pelas Regras 2, 4, 5, 7, 9, 10, 11 e 12, respectivamente.

④ **Não identificados**: total de segmentos que não foram identificados por nenhuma regra. É a diferença entre o total de objetos da classe – indicado entre parênteses ao lado do nome da classe, no cabeçalho – e o total de objetos Identificados. Para a classe Telha Cerâmica Escura, é a diferença entre (229 objetos desta classe) – (214 objetos Identificados).

⑤ **Corretos (coluna)**: é o total de acertos na regra, e corresponde ao valor da célula cinza.

⑥ **Incorretos (coluna)**: é o total de erros na regra, e corresponde ao total das células da linha, descontando-se a célula cinza.

⑦ **Total de Corretos:** é o somatório dos acertos, sendo igual na direção da linha (②) ou da coluna (⑤).

⑧ **Total de Incorretos:** é o somatório dos erros, sendo igual na direção da linha (③) ou da coluna (⑥).

⑨ **Quantidade de edificações preenchidas em 50%:** para cada regra, em cada classe, foi contabilizado o número de edificações detectadas com 50% de sua área preenchida. Este valor é mostrado entre parênteses, sendo que ele está contabilizado junto aos valores de detecção de cada regra por classe. Como exemplo, na regra 4, destacada, na classe Fibrocimento Escuro foram detectadas 63 edificações, sendo que 6 dessas 63 edificações foram detectadas estando preenchidas em 50% da sua área.

⑩ **Índice de Acurácia Global do experimento (AG):** conforme fora explicado no item 5.5, o AG é o índice que avalia a acurácia global em cada experimento. É a porcentagem de acertos em relação ao total de edificações, isto é, o Total de Corretos dividido pelo Total de Edificações vetorizadas – independente da classe – multiplicado por 100. O total de edificações vetorizadas é 596. Na tabela da Figura 56 este valor é calculado dividindo-se 378 por 596 e multiplicando o resultado por 100, assim tem-se: $AG = (378 \div 596) \times 100 = 63,42\%$.

Outro índice utilizado para avaliar a acurácia dos resultados é o Índice de Acurácia por classe (AI). Conforme fora explicado no item 5.5, este índice avalia a acurácia obtida em cada uma das classes, em cada experimento. É calculado pela equação 25, que é mostrada novamente para facilitar o entendimento. A equação é

$$AI_i = \left(\frac{N - (O + C)}{N} \right) 100 \quad (26)$$

onde i é a classe; N é o total de edificações vetorizadas da classe; O são os erros omissão; e C são os erros de inclusão. Para os experimentos tipo A são calculados

quatro índices: $AI_{\text{Cer. clara}}$, $AI_{\text{Cer. escura}}$, $AI_{\text{Fib. clara}}$, $AI_{\text{Fib. escura}}$. Para os experimentos tipo B são calculados dois índices: $AI_{\text{Cerâmica}}$, $AI_{\text{Fibrocimento}}$. Os experimentos tipo C têm apenas um índice, $AI_{\text{Edificação}}$, sendo que, nestes experimentos, tem o mesmo valor que AG.

As classificações realizadas em imagens costumam ser avaliadas por meio de uma matriz de confusão, onde são confrontadas a verdade de campo e o resultado da classificação. Trata-se de uma matriz quadrada, de dimensões $n \times n$, sendo n igual ao número de classes. Nestas condições é que, normalmente, a equação 26 é aplicada. Entretanto, neste trabalho, uma vez que se verificam os resultados para cada regra, a matriz de confusão e a equação 26 não podem ser utilizadas como de costume, a menos que fosse avaliada apenas uma regra por classe. Sendo que tal condição não é satisfeita – pois, uma vez que todas as regras são avaliadas, a quantidade destas difere do número de classes –, adaptou-se este método de avaliação para os experimentos desta pesquisa.

A adaptação é feita para se obter os valores de O e C da equação do Índice de Acurácia por classe. Assim, para os Experimentos tipo A e B, o valor de O consiste do valor de Total de Incorretos em cada classe. Já o valor de C é obtido somando-se os valores de Incorretos em cada uma das regras respectivas à classe avaliada. Os Experimentos tipo C, pelo fato de haver apenas uma regra, o valor de O consiste do valor de Não Identificados, e o valor de C será sempre 0.

Para explicar melhor, é mostrado o cálculo do valor de $AI_{\text{Cer. escura}}$ da tabela da Figura 57 (um Experimento tipo A). Neste exemplo o valor de O será 45, e o valor de C será o somatório dos valores 9, 18, 14 e 17, relativos às regras 1, 3, 6, e 8, respectivamente, relativas à classe Cerâmica Escura. O valor de N é 229, o total de edificações com telhas cerâmicas escuras vetorizadas. O valor de $AI_{\text{Cer. escura}}$ é então calculado por

$$AI_{\text{Cer.escura}} = \left(\frac{N - (O + C)}{N} \right) 100 = \left(\frac{229 - (45 + (9 + 18 + 14 + 17))}{229} \right) 100 = 55,02\%$$

Assim, a acurácia obtida na classe Cerâmica Escura, no experimento em questão, é de 55,02%.

7.6.1. Experimentos 1 (Banda 1 = B)

Experimentos com atributos de textura calculados na banda B, azul do visível.


7.6.1.1. Experimento 1-A

Experimentos com atributos de textura calculados sobre a banda B, considerando quatro tipos de telhado: Telha Fibrocimento Claro, Telha Fibrocimento Escuro, Telha Cerâmica Clara, Telha Cerâmica Escura.

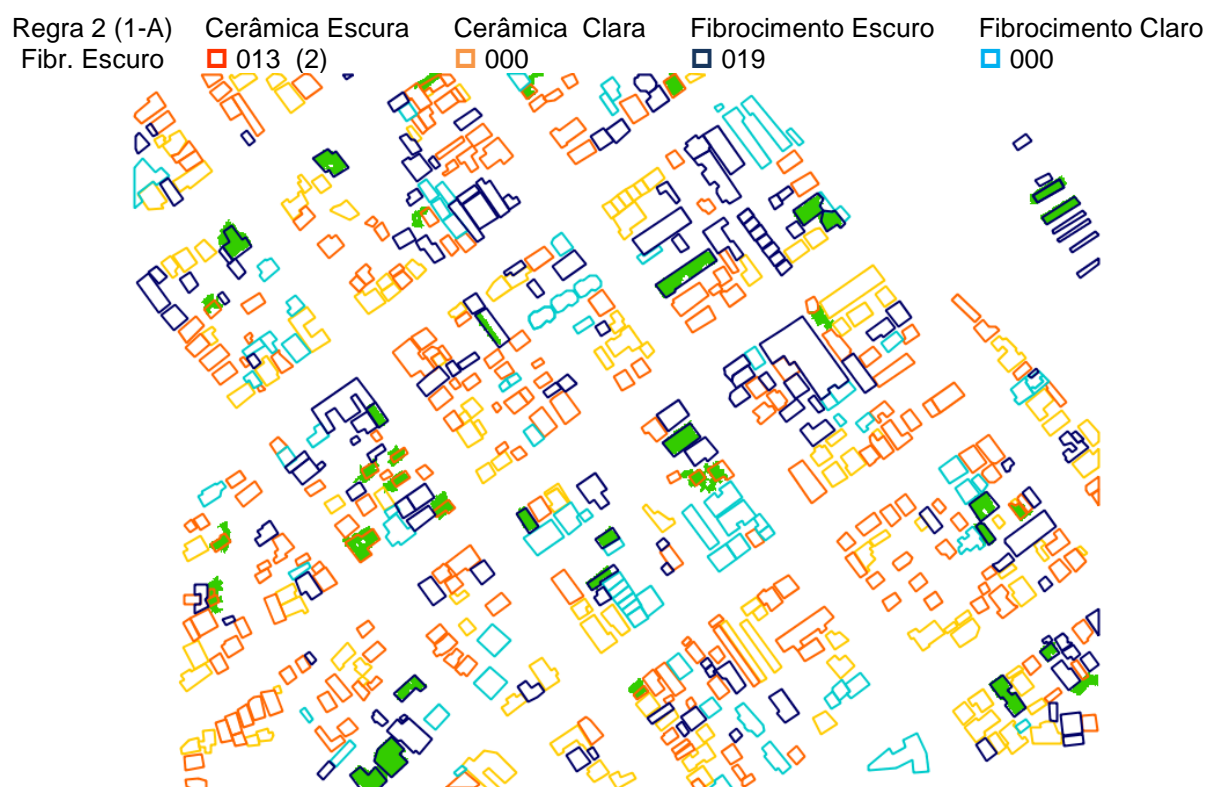
| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|---|------------|
| 1 | Se 208.374258 < MDSn <= 1052.332423 e B <= 260.64486 e 110.645985 < R <= 136.313163 e Área <= 80.625 então Telha_Cer_Escura | (2.0) |
| 2 | Se 208.374258 < MDSn <= 1052.332423 e B <= 260.64486 e 110.645985 < R <= 136.313163 e Área > 80.625 então Telha_Fibr_Escura | (6.0) |
| 3 | Se 208.374258 < MDSn <= 1052.332423 e B <= 260.64486 e 136.313163 < R <= 201.451197 então Telha_Cer_Escura | (40.0) |
| 4 | Se 208.374258 < MDSn <= 791.996119 e B > 260.64486 e 110.645985 < R <= 201.451197 então Telha_Fibr_Escura | (18.0/1.0) |
| 5 | Se 791.996119 < MDSn <= 1052.332423 e B > 260.64486 e 110.645985 < R <= 201.451197 então Telha_Fibr_Clara | (2.0) |
| 6 | Se 208.374258 < MDSn <= 1052.332423 e R > 201.451197 e Textura Média <= 322.745903 e Solidez <= 0.737983 então Telha_Cer_Escura | (4.0) |
| 7 | Se 208.374258 < MDSn <= 1052.332423 e R > 201.451197 e Textura Média em B <= 322.745903 e Solidez > 0.737983 e Desv. Pad. em R <= 36.593832 e Desv. Pad. em G <= 31.229783 então Telha_Cer_Clara | (3.0) |
| 8 | Se 208.374258 < MDSn <= 1052.332423 e R > 201.451197 e Textura Média em B <= 322.745903 e Solidez > 0.737983 e Desv. Pad. em R <= 36.593832 e Desv. Pad. em G > 31.229783 então Telha_Cer_Escura | (6.0) |
| 9 | Se 208.374258 < MDSn <= 1052.332423 e R > 201.451197 e Textura Média em B <= 322.745903 e Solidez > 0.737983 e Desv. Pad. em R > 36.593832 então Telha_Cer_Clara | (26.0/1.0) |
| 10 | Se 208.374258 < MDSn <= 1052.332423 e R > 201.451197 e Textura Média em B > 322.745903 e NIR <= 927.567766 então Telha_Fibr_Clara | (27.0) |
| 11 | Se 208.374258 < MDSn <= 1052.332423 e R > 201.451197 e Textura Média em B > 322.745903 e NIR > 927.567766 então Telha_Cer_Clara | (7.0/1.0) |
| 12 | Se MDSn > 1052.332423 e Entropia Textura em B > 0.1902 então Telha_Fibr_Clara | (2.0) |

QUADRO 08 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 1-A

FIGURA 59 – APLICAÇÃO DAS REGRAS 1 A 12, DO EXPERIMENTO 1-A




Se $208.374258 < \text{MDSn} \leq 1052.332423$ **e** $B \leq 260.64486$ **e** $110.645985 < R \leq 136.313163$ **e** $\text{Área} \leq 80.625$ **então** **Telha_Cer_Escura (2.0)**




Se $208.374258 < \text{MDSn} \leq 1052.332423$ **e** $B \leq 260.64486$ **e** $110.645985 < R \leq 136.313163$ **e** $\text{Área} > 80.625$ **então** **Telha_Fibr_Escura (6.0)**

■ Regra 3 (1-A) Cerâmica Escura Cerâmica Clara Fibrocimento Escuro Fibrocimento Claro
 Cer. Escura ■ 145 (11) ■ 001 ■ 017 (1) ■ 000




Se $208.374258 < \text{MDSn} \leq 1052.332423$ e $B \leq 260.64486$ e $136.313163 < R \leq 201.451197$ então **Telha_Cer_Escura(40.0)**

■ Regra 4 (1-A) Cerâmica Escura Cerâmica Clara Fibrocimento Escuro Fibrocimento Claro
 Fibr. Escuro ■ 021 (2) ■ 001 ■ 063 (6) ■ 005 (2)




Se $208.374258 < \text{MDSn} \leq 791.996119$ e $B > 260.64486$ e $110.645985 < R \leq 201.451197$ E **Telha_Fibr_Escura (18.0/1.0)**

■ Regra 5 (1-A) Fibr. Claro ■ Cerâmica Escura 002 (1) ■ Cerâmica Clara 000 ■ Fibrocimento Escuro 013 (4) ■ Fibrocimento Claro 004 (1)




Se $791.996119 < \text{MDSn} \leq 1052.332423$ e $B > 260.64486$ e $110.645985 < R \leq 201.451197$ então **Telha_Fibr_Clara (2.0)**

■ Regra 6 (1-A) Cer. Escura ■ Cerâmica Escura 007 (4) ■ Cerâmica Clara 013 (7) ■ Fibrocimento Escuro 001 (1) ■ Fibrocimento Claro 000



Se $208.374258 < \text{MDSn} \leq 1052.332423$ e $R > 201.451197$ e $\text{Textura Média} \leq 322.745903$ e $\text{Solidez} \leq 0.737983$ então **Telha_Cer_Escura (4.0)**




Se $208.374258 < \text{MDSn} \leq 1052.332423$ e $R > 201.451197$ e Textura Média em B ≤ 322.745903 e Solidez > 0.737983 e Desvio Padrão em R ≤ 36.593832 e Desvio Padrão em G ≤ 31.229783 então **Telha_Cer_Clara (3.0)**




Se $208.374258 < \text{MDSn} \leq 1052.332423$ e $R > 201.451197$ e Textura Média em B ≤ 322.745903 e Solidez > 0.737983 e Desvio Padrão em R ≤ 36.593832 e Desvio Padrão em G > 31.229783 então **Telha_Cer_Escura (6.0)**

■ Regra 9 (1-A) Cer. Clara
 ■ Cerâmica Escura 008 (3)
 ■ Cerâmica Clara 063 (10)
 ■ Fibrocimento Escuro 000
 ■ Fibrocimento Claro 000




Se $208.374258 < \text{MDSn} \leq 1052.332423$ e $R > 201.451197$ e Textura Média em B ≤ 322.745903 e Solidez > 0.737983 e Desvio Padrão em R > 36.593832 então **Telha_Cer_Clara (26.0/1.0)**


■ Regra 10 (1-A) Fibr. Claro
 ■ Cerâmica Escura 000
 ■ Cerâmica Clara 006 (5)
 ■ Fibrocimento Escuro 008 (6)
 ■ Fibrocimento Claro 042 (8)



Se $208.374258 < \text{MDSn} \leq 1052.332423$ e $R > 201.451197$ e Textura Média em B > 322.745903 e NIR ≤ 927.567766 então **Telha_Fibr_Clara(27.0)**



Se $208.374258 < \text{MDSn} \leq 1052.332423$ e $R > 201.451197$ e Textura Média em B > 322.745903 e NIR > 927.567766 então Telha_Cer_Clara (7.0/1.0)



Se $\text{MDSn} > 1052.332423$ e Entropia Textura em B > 0.1902 então Telha_Fibr_Clara(2.0)

| Regra | Cer. Escura: 229 | | Cer. Clara: 128 | | Fib. Escuro: 156 | | Fib. Claro: 83 | | Corretos | Incorretos |
|-------------------|------------------|------|-----------------|------|------------------|------|----------------|------|----------|------------|
| 1 Cer. Escura | 9 | (4) | 0 | 0 | 9 | (4) | 0 | 0 | 9 | (4) |
| 2 Fibr. Escura | 13 | (2) | 0 | 0 | 19 | 0 | 0 | 0 | 19 | (2) |
| 3 Cer. Escura | 145 | (11) | 1 | 0 | 17 | (1) | 0 | 0 | 145 | (11) |
| 4 Fibr. Escuro | 21 | (2) | 1 | 0 | 63 | (6) | 5 | (2) | 63 | (6) |
| 5 Fibr. Claro | 2 | (1) | 0 | 0 | 13 | (4) | 4 | (1) | 4 | (1) |
| 6 Cer. Escura | 7 | (4) | 13 | (7) | 1 | (1) | 0 | 0 | 7 | (4) |
| 7 Cer. Clara | 1 | (1) | 8 | (5) | 0 | 0 | 0 | 0 | 8 | (5) |
| 8 Cer. Escura | 8 | (5) | 16 | (7) | 0 | 0 | 1 | 0 | 8 | (5) |
| 9 Cer. Clara | 8 | (3) | 63 | (10) | 0 | 0 | 0 | 0 | 63 | (10) |
| 10 Fibr. Claro | 0 | 0 | 6 | (5) | 8 | (6) | 42 | (8) | 42 | (8) |
| 11 Cer. Clara | 0 | 0 | 7 | (7) | 3 | (2) | 12 | (8) | 7 | (7) |
| 12 Fibr. Claro | 0 | 0 | 0 | 0 | 0 | 0 | 3 | 0 | 3 | 0 |
| Identificados | 214 | (33) | 115 | (41) | 133 | (24) | 67 | (19) | | |
| Corretos | 169 | (24) | 78 | (22) | 82 | (6) | 49 | (9) | 378 | (61) |
| Incorretos | 45 | (9) | 37 | (19) | 51 | (18) | 18 | (10) | 63.42% | 151 |
| Não Identificados | 15 | | 13 | | 23 | | 16 | | | |

$$AI_{\text{Cer. Escura}} = 55.02\% \quad AI_{\text{Cer. Clara}} = 52.34\% \quad AI_{\text{Fib. Escuro}} = 41.67\% \quad AI_{\text{Fib. Claro}} = 43.37\%$$

TABELA 01 – RESULTADOS DO EXPERIMENTO 1-A

7.6.1.1.1. Análise dos resultados dos Experimentos 1-A

O Experimento 1-A, onde havia quatro classes referentes às edificações, gerou 12 regras para edificações. Foram geradas mais regras do que nos experimentos 1-B e 1-C, uma vez que um maior número de classes tende a gerar mais regras, pois o maior número de classes aumenta as possibilidades e necessidades de separação das amostras devido à maior heterogeneidade nos dados. A heterogeneidade também tende a gerar regras com maior número de nós, ou seja, com mais atributos considerados. Como exemplos se observam as regras 7 e 8, em que ambas possuem 6 nós até a definição das classes.

A árvore de decisão iniciou a divisão de amostras considerando a média de altura dos segmentos, o MDSn (AVGBAND_2). Assim, inicialmente fez-se a divisão entre os segmentos maiores que 208, 374258 cm, onde se separou a amostra entre as classes relativas a feições acima do solo – como tipos de Telhado e Árvore –, e as classes relativas a feições ao nível do solo – como Pav. Cimentado, Gramado e Asfalto. Posteriormente, na subdivisão das amostras acima do solo, há ainda outra divisão entre feições mais altas que 1052,332423 cm e mais baixas que 1052,332423 cm, pois na amostra havia árvores altas e prédios altos com telhado de fibrocimento claro.

O atributo de média na banda do vermelho (AVGBAND_4) separou feições escuras de Sombra e Fundo, de feições menos escuras como Asfalto, Pavimento e Gramado. Ainda, através do NDVI (BANDRATIO), fez-se a divisão entre Gramado e Pav. Cimentado. A Textura Média em B (TX_MEAN) foi utilizada para separar amostras de telhados, mas sem prover uma divisão de tipos específicos de telhados. A Entropia de Textura em B (TX_ENTROPY) também foi utilizada, mas apenas separou as edificações altas com telhado de fibrocimento claro de árvores também altas.

A Matriz de Confusão, mostrada no Apêndice B, mostrou a confusão entre as classes Telha Cerâmica Escura e Telha Cerâmica Clara, bem como entre as classes Telha de Fibrocimento Escura e Telha de Fibrocimento Clara. Ou seja, a distinção entre tonalidades escura e clara propiciam erros de classificação, visto que tal distinção é por vezes difícil de ser feita durante a coleta das amostras, dada a grande variação espectral da imagem frente à incapacidade humana de distinção de tonalidades.

Observando-se os resultados da aplicação das regras, nota-se que há mais de uma regra para cada uma das classes de telhado, mas, dentre estas, existem regras que obtiveram maior número de acertos em cada classe. As regras 3, 4, 9 e 10 obtiveram maior número de acertos para as classes Telha Cerâmica Escura, Telha Fibrocimento Escuro, Telha Cerâmica Clara e Telha Fibrocimento Claro, respectivamente. Esta quantidade de acerto obtida é condizente com o desempenho destas regras frente às suas amostras na árvore de decisão, como se observa na terceira coluna do Quadro 08. Ainda nestas regras, nota-se que apenas uma delas considera um atributo de forma – a Solidez – enquanto que as demais apenas consideram atributos espectrais. A Solidez se fez presente na regra 9 ao separar 4 (quatro) segmentos de Telha Cerâmica Escura (Regra 6) do restante da amostra que ainda continha outros 6 (seis) segmentos de Telha Cerâmica Escura e 30 (trinta) de Telha Cerâmica Clara. Ou seja, a Solidez não separou uma classe específica, mas apenas alguns segmentos da classe Telha Cerâmica Escura. Este atributo está presente nas regras 7 e 8, ambas com menor número de acertos.

As Regras 1 e 2 diferem-se pelo atributo de Área, mas ambas conduzem a mesma classe de Telha Cerâmica Escura. Isso caracterizou outra particularidade da amostra e não distinguiu classes.

Analisando a árvore de decisão, suas regras e os resultados da aplicação das mesmas, nota-se que os atributos de forma – que, teoricamente, caracterizariam uma vantagem da análise de imagens baseada em objetos – foram utilizados apenas quando haviam sido feitas várias subdivisões anteriores nas amostras. Isto mostra que tais atributos só propiciaram maior ganho de informação em amostras pequenas. Em outras palavras, apenas quando havia poucos segmentos na amostra é que houve alguma padronização de forma capaz de possibilitar ganho de informação. Entretanto, isto não propiciou a distinção de classes. Foram utilizados os atributos de Solidez (SOLIDITY), Área (AREA) e Comprimento do Perímetro (LENGHT), mas, ainda que propiciando ganho de informação entre as amostras, não trouxeram divisões importantes, pois: (1) a Área separou alguns poucos segmentos de Telhas Cerâmicas Escuras de alguns poucos segmentos de Telhas de Fibrocimento Escuras; (2) a Solidez separou alguns segmentos de Telha Cerâmica Escura de outros segmentos também de Telha Cerâmica Escura; (3) e o Comprimento do Perímetro separou segmentos de Sombra de segmentos de Árvore, sendo que tal separação não é condizente com atributos de forma, mas sim com atributos espectrais, e só ocorreu devido à particularidade da amostra.

7.6.1.2. Experimento 1-B

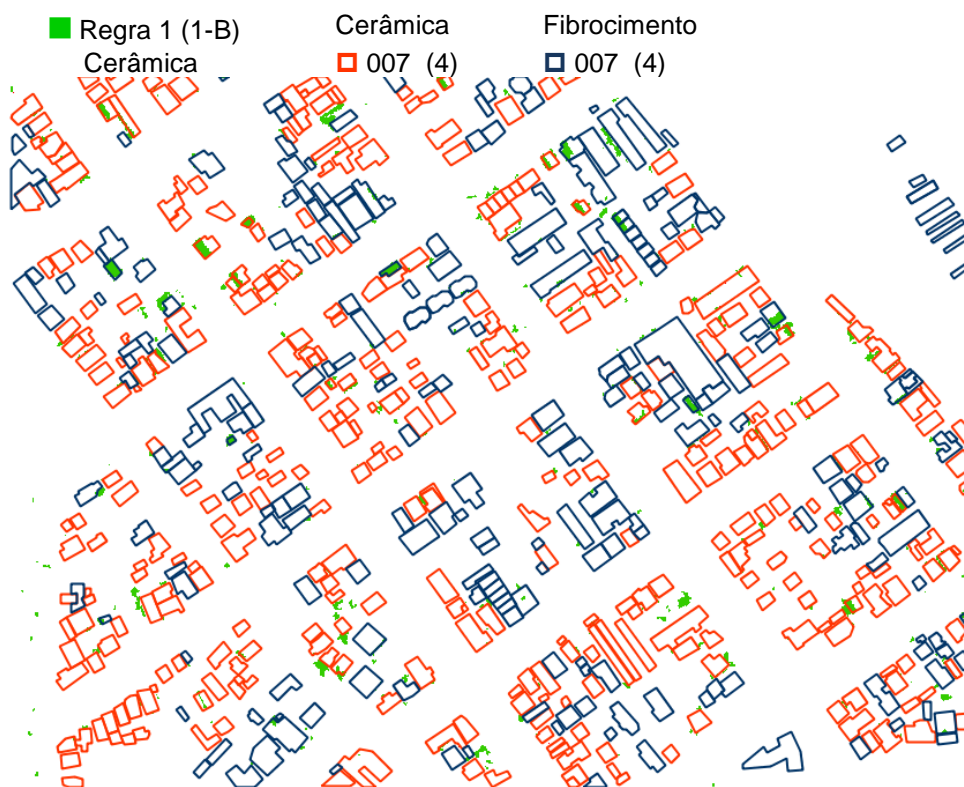
Experimentos com atributos de textura calculados sobre a banda B, considerando dois tipos de telhado: Telhado Cerâmico e Telhado de Fibrocimento. A árvore de decisão e sua respectiva matriz confusão, gerados no Weka, são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|---|-------|
| 1 | Se MDSn > 208.374258 e Tx. Média em B <= 339.053937 e B <= 259.677755 e 110.645985 < R <= 136.313163 e NIR <= 555.124582 e Area <=80.625 então Telha_Ceramica | (2.0) |
| 2 | Se MDSn > 208.374258 e Tx Média em B <= 339.053937 e B <= 259.677755 e 110.645985 < R <= 136.313163 e NIR <= 555.124582 e Area >80.625 então Telha_Fibrocimento | (6.0) |

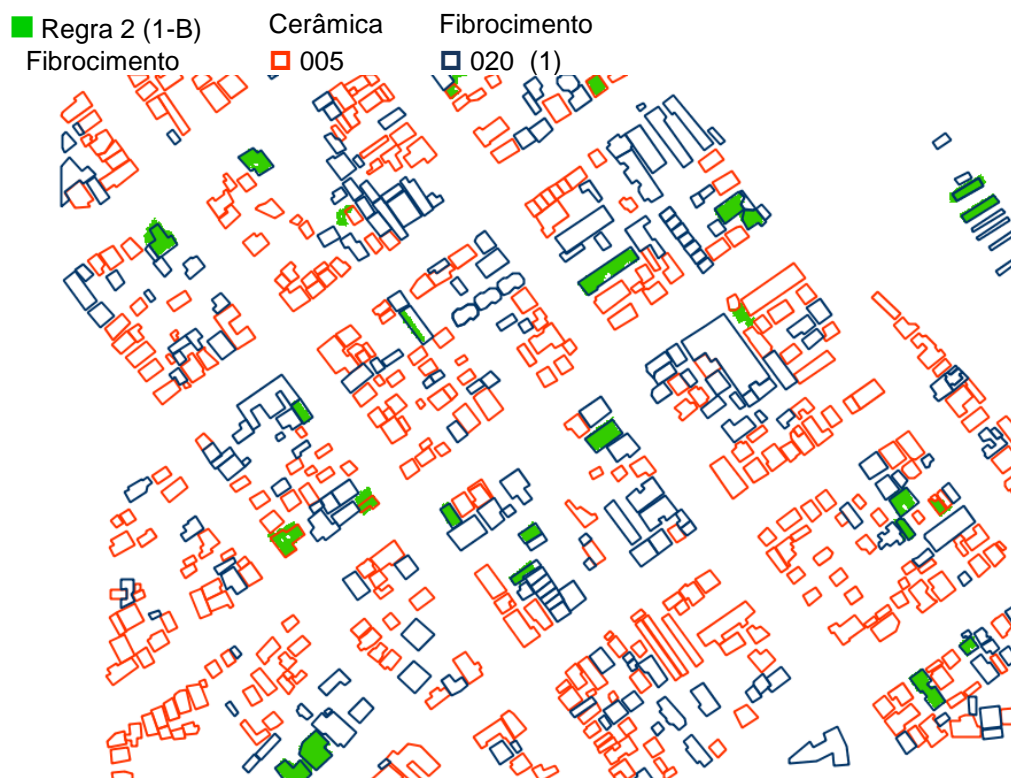
| | | |
|---|--|------------|
| 3 | Se MDSn > 208.374258 e Tx. Média em B <= 339.053937 e B <= 259.677755 e R > 136.313163 e NIR <= 555.124582 então Telha_Ceramica | (9.0) |
| 4 | Se MDSn > 208.374258 e R > 110.645985 e Tx Média em B <= 339.053937 e NIR <= 555.124582 e B > 259.677755 então Telha_Fibrocimento | (17.0) |
| 5 | Se MDSn > 208.374258 e R > 110.645985 e Tx. Média em B <= 339.053937 e NIR > 555.124582 e Intervalo de Textura em B <= 67.847059 então Telha_Ceramica | (65.0/1.0) |
| 6 | Se MDSn > 208.374258 e R > 110.645985 e Tx. Média em B <= 339.053937 e Intervalo de Textura em B > 67.847059 e 555.124582 < NIR <= 631.022814 então Telha_Fibrocimento | (3.0) |
| 7 | Se MDSn > 208.374258 e R > 110.645985 e Tx. Média em B <= 339.053937 e Intervalo de Textura em B > 67.847059 e NIR > 631.022814 então Telha_Ceramica | (8.0/1.0) |
| 8 | Se MDSn > 208.374258 e Tx. Média em B > 339.053937 e 110.645985 < R <= 417.750958 então Telha_Fibrocimento | (29.0) |
| 9 | Se MDSn > 208.374258 e Tx. Média em B > 339.053937 e R > 417.750958 então Telha_Ceramica | (5.0) |

QUADRO 09 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 1-B

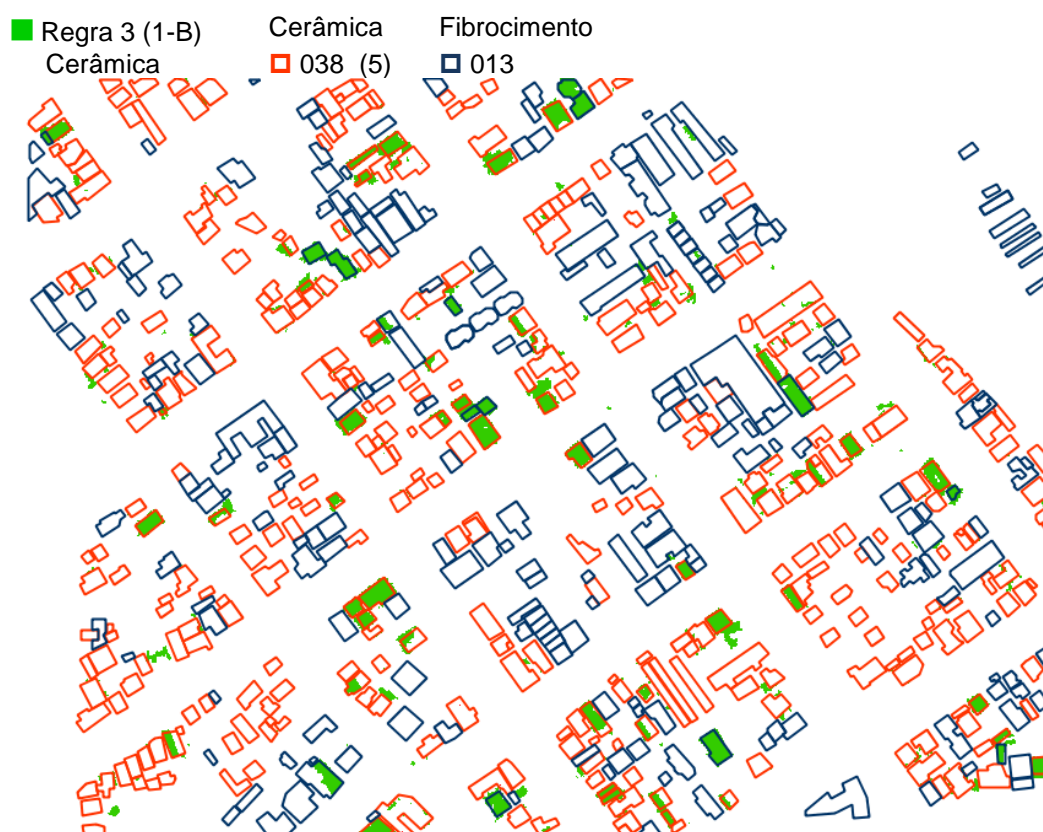
FIGURA 60 – APLICAÇÃO DAS REGRAS 1 A 9, DO EXPERIMENTO 1-B



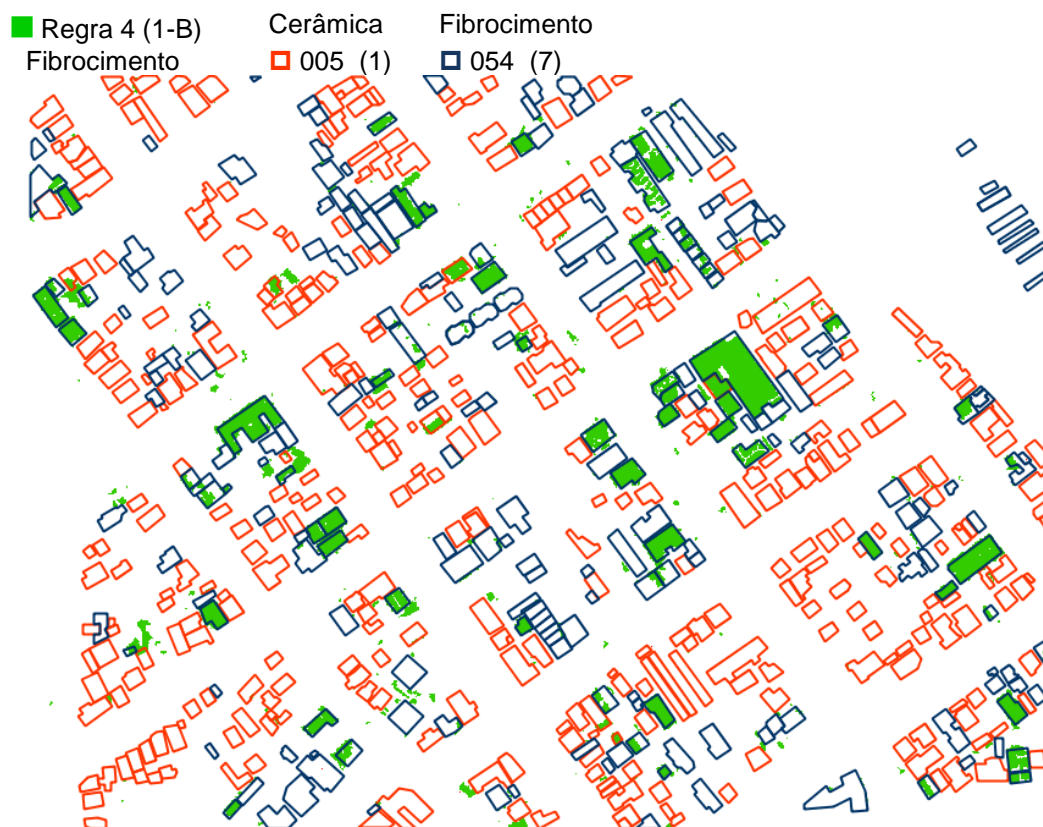
Se MDSn > 208.374258 **e** Tx. Média em B <= 339.053937 **e** B <= 259.677755 **e** 110.645985 < R <= 136.313163 **e** NIR <= 555.124582 **e** Area <=80.625 **então** Telha_Ceramica (2.0)



Se MDSn > 208.374258 **e** Tx Média em B <= 339.053937 **e** B <= 259.677755 **e** 110.645985 < R <= 136.313163 **e** NIR <= 555.124582 **e** Area >80.625 **então** Telha_Fibrocimento (6.0)



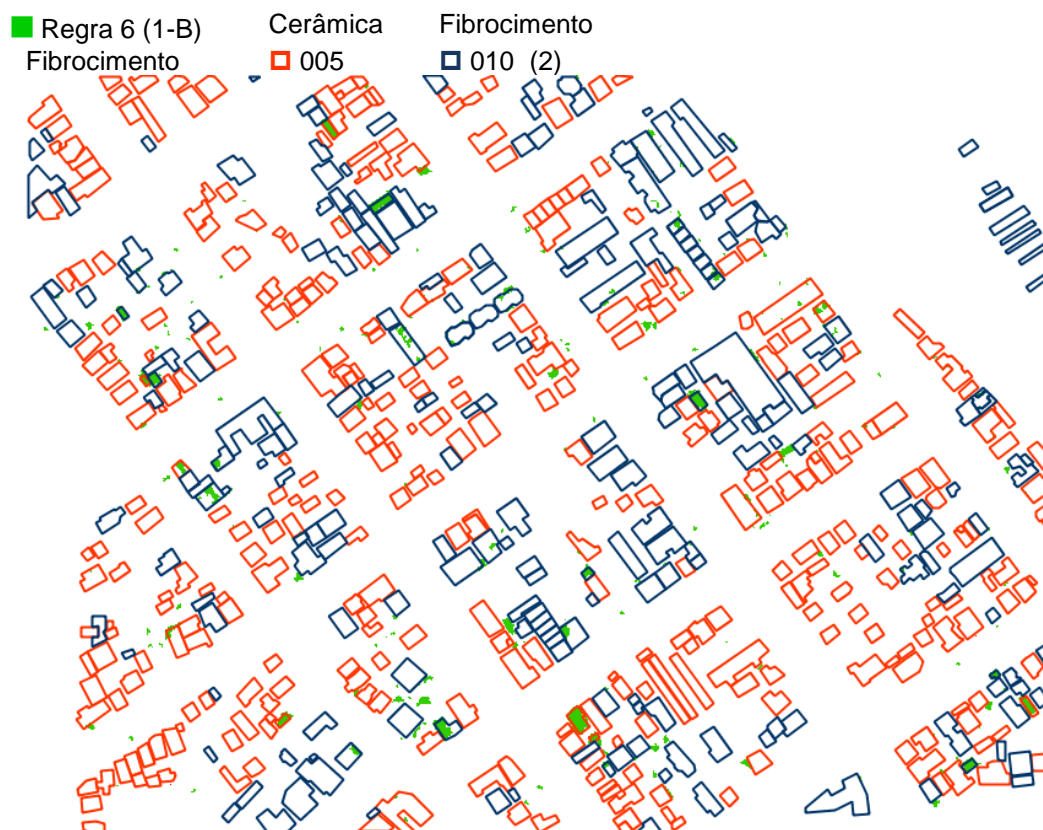
Se MDSn > 208.374258 **e** Tx. Média em B <= 339.053937 **e** B <= 259.677755 **e** R > 136.313163 **e** NIR <= 555.124582 **então** Telha_Ceramica (9.0)



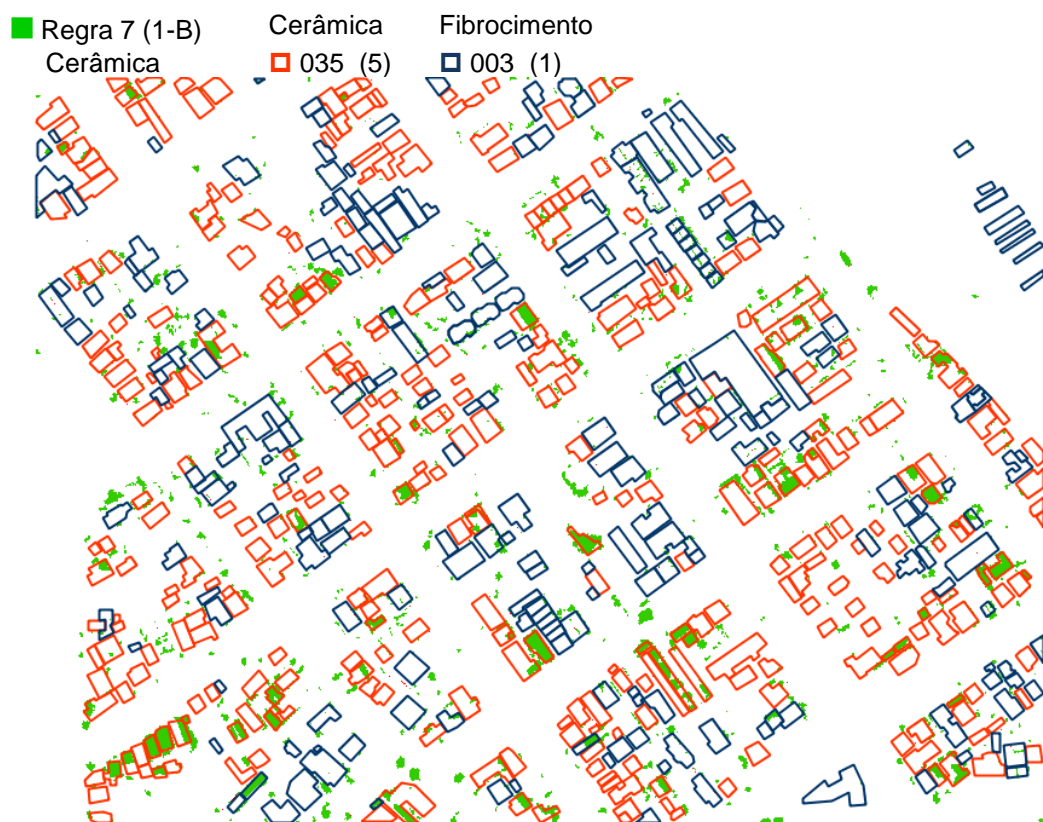
Se $MDSn > 208.374258$ e $R > 110.645985$ e Tx Média em B ≤ 339.053937 e $NIR \leq 555.124582$ e $B > 259.677755$ então **Telha_Fibrocimento(17.0)**



Se $MDSn > 208.374258$ e $R > 110.645985$ e Tx. Média em B ≤ 339.053937 e $NIR > 555.124582$ e Intervalo de Textura em B ≤ 67.847059 então **Telha_Ceramica (65.0/1.0)**



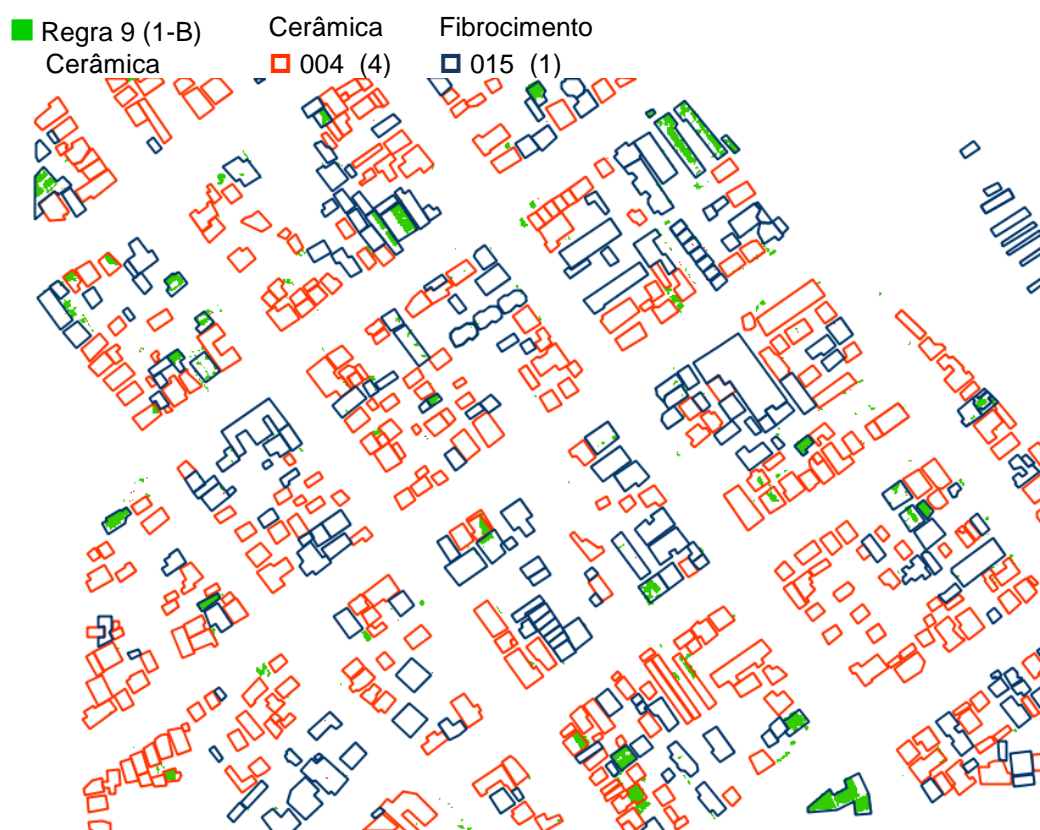
Se MDSn > 208.374258 **e** R > 110.645985 **e** Tx. Média em B <= 339.053937 **e** Intervalo de Textura em B > 67.847059 **e** 555.124582 < NIR <= 631.022814 **então** Telha_Fibrocimento(3.0)



Se MDSn > 208.374258 **e** R > 110.645985 **e** Tx. Média em B <= 339.053937 **e** Intervalo de Textura em B > 67.847059 **e** NIR > 631.022814 **então** Telha_Ceramica(8.0/1.0)



Se $MDSn > 208.374258$ e Tx. Média em B > 339.053937 e $110.645985 < R \leq 417.750958$ então **Telha_Fibrocimento(29.0)**



Se $MDSn > 208.374258$ e Tx. Média em B > 339.053937 e $R > 417.750958$ então **Telha_Ceramica(5.0)**

| Regra | | Cerâmica (357) | | Fibrocimento (239) | | Corretos | | Incorretos | |
|-------------------|--------------|----------------|------|--------------------|------|----------|------|------------|------|
| 1 | Cerâmica | 7 | (4) | 7 | (4) | 7 | (4) | 7 | (4) |
| 2 | Fibrocimento | 5 | 0 | 20 | (1) | 20 | (1) | 5 | 0 |
| 3 | Cerâmica | 38 | (5) | 13 | 0 | 38 | (5) | 13 | 0 |
| 4 | Fibrocimento | 5 | (1) | 54 | (7) | 54 | (7) | 5 | (1) |
| 5 | Cerâmica | 227 | (19) | 32 | (1) | 227 | (19) | 32 | (1) |
| 6 | Fibrocimento | 5 | 0 | 10 | (2) | 10 | (2) | 5 | 0 |
| 7 | Cerâmica | 35 | (5) | 3 | (1) | 35 | (5) | 3 | (1) |
| 8 | Fibrocimento | 9 | (6) | 55 | (4) | 55 | (4) | 9 | (6) |
| 9 | Cerâmica | 4 | (4) | 15 | (1) | 4 | (4) | 15 | (1) |
| Identificados | | 335 | (44) | 209 | (21) | | | | |
| Corretos | | 311 | (37) | 139 | (14) | 450 | (51) | | |
| Incorretos | | 24 | (7) | 70 | (7) | 75.50% | | 94 | (14) |
| Não Identificados | | 22 | | 30 | | | | | |

$$AI_{\text{Cerâmica}} = 73.67\% \quad AI_{\text{Fibrocimento}} = 70.71\%$$

TABELA 02 – RESULTADOS DO EXPERIMENTO 1-B

7.6.1.2.1. Análise dos resultados do Experimento 1-B

O Experimento 1-B possui apenas a distinção de classe de Telhas de Fibrocimento e Telhado Cerâmico, sem distinção de tonalidade clara ou escura, e gerou uma árvore menor, mais simples, com 9 regras para edificações. Também teve a árvore de decisão iniciando pelo MDSn (AVGBAND_2) com o valor de 208,374258 cm – as amostras eram as mesmas – que separou as feições acima do solo das feições ao nível do solo. Nas feições ao nível do solo, o atributo de média na banda do vermelho separou feições muito escuras como Sombra e Fundo, de outras menos escuras, como Pavimento Cimentado e Asfalto. Ainda nesta sequência, o NDVI (BANDRATIO) distinguiu o Gramado das pavimentações.

Nas feições acima do solo encontram-se as regras para as edificações e, dentre estas, destaca-se a Regra 5 para Telha Cerâmica, bem como as Regras 4 e 8 para Telha Fibrocimento. Tais regras obtiveram maior número de acertos na suas classes, sendo condizentes com os seus desempenhos nas amostras da árvore de decisão, onde também se destacaram pelo maior número de acertos. Em nenhuma destas há a consideração de atributos de forma, apenas espectrais. Dentre estes atributos espectrais estão atributos de textura como a Média da Textura em B

(TX_MEAN) e a Amplitude da Textura em B (TX_RANGE), que não separaram as classes completamente, apenas geraram amostras mais homogêneas por este atributo.


7.6.1.3. Experimento 1-C

Experimentos com atributos de textura calculados sobre a banda B, considerando apenas a classe Edificação. A árvore de decisão e sua respectiva matriz confusão, gerados no Weka, são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|--|-------------|
| Única | Se MDSn > 208.374258 e R > 110.645985 então Edificacao | (144.0/1.0) |

QUADRO 10 – REGRA REFERENTE À EDIFICAÇÃO NO EXPERIMENTO 1-C

FIGURA 61 – APLICAÇÃO DA REGRA ÚNICA DO EXPERIMENTO 1-C



| Regra | | Edificação | | Corretos | | Incorretos | |
|-------------------|------------|------------|---|----------|---|------------|---|
| U | Edificação | 585 | 0 | 585 | 0 | 0 | 0 |
| Identificados | | 585 | 0 | | | | |
| Corretos | | 585 | 0 | | | | |
| Incorretos | | 0 | 0 | 98.15% | | 0 | 0 |
| Não Identificados | | 11 | | | | | |

$$AI_{\text{Edificação}} = 98.15\%$$

TABELA 03 – RESULTADOS DO EXPERIMENTO 1-C

7.6.1.3.1. Análise dos resultados do Experimento 1-C

O Experimento 1-C, onde há apenas a classe EDIFICACAO referente às edificações, sem qualquer distinção de tipos de telhado, apresentou a menor árvore de decisão, sendo mais eficiente. Observa-se que apenas o MDSn (AVGBAND_2) e a média na banda R (AVGBAND_4) conduzem à classe EDIFICACAO, e o resultado da aplicação desta regra identificou 585 edificações dentre as 596 existentes. O MDSn separou as feições ao nível do solo de feições acima do solo. A média da banda R, nas feições acima do solo, separou as edificações das árvores e sombras. O NDVI (BANDRATIO) foi utilizado para separar pavimentos de gramados, nas feições ao nível do solo; e separar árvores de sombras, nas feições acima do solo. Entretanto, na regra para Edificação, o atributo de média da banda R prevaleceu sobre o NDVI. Nenhum atributo de textura ou de forma foi considerado.

7.6.2. Experimentos 2 (Banda 1 = G)

Estes experimentos possuem atributos de textura calculados sobre a banda G, verde do visível.

7.6.2.1. Experimento 2-A

Experimentos com atributos de textura calculados sobre a banda G, considerando quatro tipos de telhado: Telhado Fibrocimento Claro, Telhado Fibrocimento Escuro, Telhado Cerâmico Claro, Telhado Cerâmico Escuro. A árvore de decisão e sua respectiva matriz confusão, gerados no Weka, são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|---|------------|
| 1 | Se MDSn > 210.131015 e 102.633929 < R <= 143.754902 e B <= 267.909677 e Area <= 79.25 e Dir. Principal > 79.916457 então Telha_Cer_Escura | (3.0) |
| 2 | Se MDSn > 210.131015 e 102.633929 < R <= 143.754902 e B <= 267.909677 e Area > 79.25 então Telha_Fibr_Escura | (7.0) |
| 3 | Se MDSn > 210.131015 e 143.754902 < R <= 256.105485 e B <= 267.909677 então Telha_Cer_Escura | (43.0/1.0) |
| 4 | Se MDSn > 210.131015 e 102.633929 < R <= 256.105485 e 267.909677 < B <= 326.552846 e Mínimo em B <= 214 então Telha_Fibr_Escura | (16.0/1.0) |
| 5 | Se MDSn > 210.131015 e 102.633929 < R <= 256.105485 e 267.909677 < B <= 326.552846 e Mínimo em B >= 214 então Telha_Fibr_Clara | (3.0/1.0) |
| 6 | Se MDSn > 210.131015 e B <= 326.552846 e R > 256.105485 e Entr. Textura em G <= 0.192646 e Convexidade <= 1.30039 então Telha_Cer_Clara | (28.0/1.0) |
| 7 | Se MDSn > 210.131015 e B <= 326.552846 e R > 256.105485 e Entr. Textura em G <= 0.192646 e Convexidade > 1.30039 então Telha_Cer_Escura | (2.0) |
| 8 | Se MDSn > 210.131015 e B <= 326.552846 e R > 256.105485 e Entr. Textura em G > 0.192646 então Telha_Cer_Escura | (4.0) |
| 9 | Se MDSn > 210.131015 e B > 326.552846 e 102.633929 < R <= 391.686441 então Telha_Fibr_Clara | (34.0/1.0) |
| 10 | Se MDSn > 210.131015 e B > 326.552846 e R > 391.686441 então Telha_Cer_Clara | (7.0/1.0) |

QUADRO 11 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 2-A

| Regra | | Cer. Escura: 229 | | Cer. Clara: 128 | | Fibr. Escuro: 156 | | Fibr. Claro: 83 | | Corretos | | Incorretos | |
|-------------------|--------------|------------------|------|-----------------|------|-------------------|------|-----------------|-----|----------|------|------------|------|
| 1 | Cer. Escura | 8 | (6) | 0 | 0 | 7 | (3) | 0 | 0 | 8 | (6) | 7 | (3) |
| 2 | Fibr. Escuro | 19 | (2) | 0 | 0 | 34 | (2) | 0 | 0 | 34 | (2) | 19 | (2) |
| 3 | Cer. Escura | 166 | (13) | 7 | (3) | 18 | (1) | 0 | 0 | 166 | (13) | 25 | (4) |
| 4 | Fibr. Escuro | 13 | 0 | 2 | (1) | 38 | 0 | 6 | 0 | 38 | 0 | 21 | (1) |
| 5 | Fibr. Claro | 5 | (1) | 3 | (1) | 20 | (3) | 4 | 0 | 4 | 0 | 28 | (5) |
| 6 | Cer. Clara | 4 | (2) | 71 | (12) | 0 | 0 | 0 | 0 | 71 | (12) | 4 | (2) |
| 7 | Cer. Escura | 5 | (2) | 7 | 0 | 0 | 0 | 0 | 0 | 5 | (2) | 7 | 0 |
| 8 | Cer. Escura | 1 | (1) | 8 | (2) | 0 | 0 | 0 | 0 | 1 | (1) | 8 | (2) |
| 9 | Fibr. Claro | 0 | 0 | 8 | (2) | 9 | (6) | 46 | (2) | 46 | (2) | 17 | (8) |
| 10 | Cer. Clara | 0 | 0 | 12 | (6) | 3 | (2) | 15 | (4) | 12 | (6) | 18 | (6) |
| Identificados | | 221 | (27) | 118 | (27) | 129 | (17) | 71 | (6) | | | | |
| Corretos | | 180 | (22) | 83 | (18) | 72 | (2) | 50 | (2) | 385 | (44) | | |
| Incorretos | | 41 | (5) | 35 | (9) | 57 | (15) | 21 | (4) | 64.60% | | 154 | (33) |
| Não Identificados | | 8 | | 10 | | 27 | | 12 | | | | | |

$$AI_{\text{Cer. Escura}} = 61.57\% \quad AI_{\text{Cer. Clara}} = 55.47\% \quad AI_{\text{Fibr. Escuro}} = 37.82\% \quad AI_{\text{Fibr. Claro}} = 20.48\%$$

TABELA 04 – RESULTADOS DO EXPERIMENTO 2-A

7.6.2.1.1. Análise dos resultados do Experimento 2-A

O Experimento 2-A gerou 10 regras para edificações. Assim como ocorrera nos Experimentos 1, este Experimento 2-A gerou mais regras do que nos experimentos 2-B e 2-C.

A árvore de decisão iniciou a divisão de amostras considerando a média de altura dos segmentos, o MDSn (AVGBAND_2). Assim, inicialmente fez-se a divisão entre os segmentos maiores que 210,131015 cm, onde se separou a amostra entre as classes relativas a feições acima do solo – como Telhado e Árvore –, e as classes relativas a feições ao nível do solo – como Pav. Cimentado, Gramado e Asfalto.

Nas feições ao nível do solo, a média na banda B (AVGBAND_3) separou as classes de Pav. Cimentado e Asfalto das classes de Gramado, Sombra e Fundo. Posteriormente a Média de Textura na banda G separou Pav. Cimentado e Asfalto. A classe Fundo distinguiu-se da classe Sombra pelo valor Mínimo na Banda B, que era igual a 0 (zero).

Nas feições acima do solo, a média na banda R (AVGBAND_4) separou as feições Sombra e Árvore das feições de Telhas. Ainda, através do NDVI (BANDRATIO), fez-se a distinção entre Sombra e Árvore. A Entropia de Textura em

G (TX_ENTROPY) também foi utilizada, mas apenas separou algumas edificações com telhado de cerâmica escura.

A Matriz de Confusão mostrou confusão entre as classes Telha Cerâmica Escura e Telha Cerâmica Clara maior que a confusão entre as classes Telha de Fibrocimento Escura e Telha de Fibrocimento Clara.

As regras 2, 3, 4, 6 e 9 obtiveram maior número de acertos para as classes Telha Fibrocimento Escuro, Telha Cerâmica Escura, novamente Telha Fibrocimento Escuro, Telha Cerâmica Clara e Telha Fibrocimento Claro, respectivamente. As regras 2 e 4 dividem o maior número de acertos na classe Telha Fibrocimento Escuro, mesmo que o número de acertos da regra 2 na árvore de decisão seja menor. Nas demais regras a quantidade de acerto obtida é condizente com o desempenho destas frente às suas amostras na árvore de decisão, como se observa na terceira coluna do Quadro 11. As regras 2 e 6 consideram os atributos de forma Área e Convexidade, respectivamente, enquanto que as demais apenas consideram atributos espectrais. Estes dois atributos foram os últimos a serem considerados nas suas respectivas regras, sendo, respectivamente, o sétimo e o sexto particionamento da regra. Com um critério de poda mais rígido – que pode ser alterado pela configuração do J48 no Weka – estes atributo teriam sido podados, não sendo, por fim, considerados na regra.

Assim como no Experimento 1-A, neste experimento também ocorreu dos atributos de forma – que caracterizam uma vantagem da análise de imagens baseada em objetos – serem utilizados apenas quando haviam sido feitas várias subdivisões anteriores nas amostras, caracterizando que tais atributos só propiciaram maior ganho de informação em amostras pequenas. Apesar destes atributos de forma terem separado classes distintas, tais separações seriam mais condizentes com atributos espectrais. A Área separou as classes Arvore e Telha Cerâmica Escura da classe Telha Fibrocimento Escura. Esta separação não foi realizada previamente pelos atributos espectrais devido à semelhança entre algumas amostras de edificações de telhado de fibrocimento escuro com edificações com telhados cerâmicos escuros muito velhos, que tendem a perder sua tonalidade avermelhada, tornando-se mais escuros, de tonalidade cinza escura ou marrom. A Convexidade separou Telha Cerâmica Clara de Telha Cerâmica Escura, sendo outro caso em que a distinção de classes é mais plausível de ser realizada por atributos espectrais.

7.6.2.2. Experimento 2-B

Experimentos com atributos de textura calculados sobre a banda G, considerando dois tipos de telhado: Telhado Cerâmico e Telhado de Fibrocimento. A árvore de decisão e sua respectiva matriz confusão, gerados no Weka, são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|---|------------|
| 1 | Se MDSn > 210.131015 e NDVI <= 0.628041 e R > 102.633929 e B <= 260.312236 e NIR <= 558.520833 e Mínimo em R <= 57 e Matiz <= 217.127233 então Telha_Fibrocimento | (5.0) |
| 2 | Se MDSn > 210.131015 e NDVI <= 0.628041 e R > 102.633929 e B <= 260.312236 e NIR <= 558.520833 e Mínimo em R <= 57 e Matiz > 217.127233 então Telha_Ceramica | (4.0/1.0) |
| 3 | Se MDSn > 210.131015 e NDVI <= 0.628041 e R > 102.633929 e B <= 260.312236 e NIR <= 558.520833 e Mínimo em R > 57 então Telha_Ceramica | (11.0) |
| 4 | Se MDSn > 210.131015 e NDVI <= 0.628041 e R > 102.633929 e 260.312236 < B <= 326.552846 e NIR <= 558.520833 então Telha_Fibrocimento | (17.0) |
| 5 | Se MDSn > 210.131015 e NDVI <= 0.628041 e R > 102.633929 e B <= 326.552846 e NIR > 558.520833 então Telha_Ceramica | (70.0/2.0) |
| 6 | Se MDSn > 210.131015 e NDVI <= 0.628041 e 102.633929 < R <= 391.686441 e B > 326.552846 então Telha_Fibrocimento | (34.0) |
| 7 | Se MDSn > 210.131015 e NDVI <= 0.628041 e R > 391.686441 e B > 326.552846 então Telha_Ceramica | (7.0/1.0) |

QUADRO 12 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 2-B

| Regra | | Cerâmica (357) | | Fibrocimento (239) | | Corretos | | Incorretos | |
|-------------------|--------------|----------------|------|--------------------|------|----------|------|------------|------|
| 1 | Fibrocimento | 10 | (2) | 26 | (1) | 26 | (1) | 10 | (2) |
| 2 | Cerâmica | 10 | (1) | 4 | (1) | 10 | (1) | 4 | (1) |
| 3 | Cerâmica | 29 | (6) | 13 | (5) | 29 | (6) | 13 | (5) |
| 4 | Fibrocimento | 5 | (1) | 56 | (9) | 56 | (9) | 5 | (1) |
| 5 | Cerâmica | 256 | (21) | 37 | (1) | 256 | (21) | 37 | (1) |
| 6 | Fibrocimento | 7 | (1) | 57 | (6) | 57 | (6) | 7 | (1) |
| 7 | Cerâmica | 10 | (9) | 21 | (2) | 10 | (9) | 21 | (2) |
| Identificados | | 327 | (41) | 214 | (25) | | | | |
| Corretos | | 305 | (37) | 139 | (16) | 444 | (53) | | |
| Incorretos | | 22 | (4) | 75 | (9) | 74.50% | | 97 | (13) |
| Não Identificados | | 30 | | 25 | | | | | |

$$AI_{\text{Ceramica}} = 72.83\% \quad AI_{\text{Fibrocimento}} = 59.41\%$$

TABELA 05 – RESULTADOS DO EXPERIMENTO 2-B

7.6.2.2.1. Análise dos resultados do Experimento 2-B

O Experimento 2-B gerou uma árvore com 7 regras para edificações. Também teve a árvore de decisão iniciando pelo MDSn (AVGBAND_2) com o valor de 210,131015 cm – as amostras eram as mesmas – que separou as feições acima do solo das feições ao nível do solo.

Nas feições ao nível do solo, a Média na Banda B (AVGBAND_3) separou classes escuras como Sombra, Fundo e Gramados, das classes Pavimento Cimentado e Asfalto. Em seguida, a Textura Média na banda G (TX_MEAN) distinguiu a classe Gramado.

A separação das classes Pav_Cimentado e Asfalto ocorreu com a utilização do Valor Máximo no MDSn (AVGBAND_2), por meio do valor 908,526611 cm, não sendo compatível com a realidade das feições destas classes. Essa separação só ocorreu devido à presença de pixels de alto valor de altura nestes segmentos. Tais pixels não foram extraídos pela filtragem mostrada no item “5.1.1.4. Filtro Morfológico de Abertura”, e acabaram por elevar o valor do atributo de Valor Máximo no MDSn. Observou-se que nas amostras coletadas, as classes ao nível do solo como Pav_Cimentado, Gramado e Asfalto ainda possuíam amostras com valor elevado neste atributo, mas com a média de altura do MDSn (AVGBAND) tendo sido corrigida. Por fim, o Valor Máximo no MDSn, mesmo que não condizente com a realidade, apresentou maior ganho de informação e foi utilizado na árvore de decisão.

Nas feições acima do solo encontram-se as regras para as edificações e, dentre estas, destacam-se a Regra 5, para Telha Cerâmica, e as Regras 4 e 6, para Telha Fibrocimento. Tais regras obtiveram maior número de acertos na suas classes, sendo condizentes com os seus desempenhos nas amostras da árvore de decisão, onde também se destacaram pelo maior número de acertos. Em nenhuma das regras há a consideração de atributos de forma nem de textura, apenas atributos espectrais. Dentre estes atributos espectrais estão o NDVI (BANDRATIO), a Média na Banda R (AVGBAND_4), e a Média na Banda B (AVGBAND_3). Ambas as regras concordam no NDVI baixo, e diferem no valor da Média na Banda B, sendo que a classe Telha Cerâmica possui valor abaixo de 326.552846 e a classe Telha Fibrocimento acima deste valor. A classe Telha Cerâmica também apresenta

valor alto para Média na Banda NIR. A Regra 4 complementa a Regra 6 por identificar a classe Telha Fibrocimento nas feições com Média na Banda B entre 260.312236 e 326.552846.

7.6.2.3. Experimento 2-C

Experimentos com atributos de textura calculados sobre a banda G, considerando apenas a classe Edificação, independente do tipo de telhado. A árvore de decisão e sua respectiva matriz confusão, gerados no Weka, são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|---|-------------|
| Única | Se $MDSn > 210.131015$ e $NDVI \leq 0.628041$ e $R > 102.633929$ então Edificacao | (148.0/1.0) |

QUADRO 13 – REGRA REFERENTE À EDIFICAÇÃO NO EXPERIMENTO 2-C

| Regra | | Edificação: 596 | | Corretos | | Incorretos | |
|-------|-------------------|-----------------|---|----------|---|------------|---|
| U | Edificação | 574 | 0 | 574 | 0 | 0 | 0 |
| | Identificados | 574 | 0 | | | | |
| | Corretos | 574 | 0 | 574 | 0 | | |
| | Incorretos | 0 | 0 | 96.31% | | 0 | 0 |
| | Não Identificados | 22 | | | | | |

$$AI_{\text{Edificação}} = 96.31\%$$

TABELA 06 – RESULTADOS DO EXPERIMENTO 2-C

7.6.2.3.1. Análise dos resultados do Experimento 2-C

No Experimento 2-C há apenas uma regra que conduz à classe Edificação e, com apenas o MDSn (AVGBAND_2), o NDVI (BANDRATIO) e a média na banda R (AVGBAND_4), define-se esta classe. O resultado da aplicação desta regra identificou 574 edificações dentre as 596 existentes. O MDSn novamente separou as

feições ao nível do solo de feições acima do solo. O NDVI, nas feições acima do solo, separou as Edificações das Árvores e de feições de Sombras acima do nível do solo. Complementarmente, a Média na Banda R refinou a classe Edificação separando 3 (três) feições de Sombra. Nas feições ao nível do solo, a Textura em G (TX_MEAN) separou a classe Gramado das classes Sombra e Fundo. Nenhum atributo de textura ou de forma foi considerado.

7.6.3. Experimentos 3 (Banda 1 = R)

Estes experimentos possuem atributos de textura calculados sobre a banda R, vermelho do visível.

7.6.3.1. Experimento 3-A

Experimentos com atributos de textura calculados sobre a banda R, considerando quatro tipos de telhado: Telhado Fibrocimento Claro, Telhado Fibrocimento Escuro, Telhado Cerâmico Claro, Telhado Cerâmico Escuro. A árvore de decisão e sua respectiva matriz confusão, gerados no Weka, são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|--|------------|
| 1 | Se G ≤ 273.720207 e Mínimo em B > 0 e NIR ≤ 572.239761 e Matiz > 215.544537 então Telha_Cer_Escura | (2.0) |
| 2 | Se G > 273.720207 e MDSn > 133.947014 e B ≤ 262.875274 e NIR ≤ 691.548872 e Tx. Média em R ≤ 143.832705 então Telha_Fibr_Escura | (7.0) |
| 3 | Se G > 273.720207 e MDSn > 133.947014 e B ≤ 262.875274 e NIR ≤ 691.548872 e Tx. Média em R > 143.832705 então Telha_Cer_Escura | (39.0) |
| 4 | Se G > 273.720207 e MDSn > 133.947014 e 262.875274 < B ≤ 326.195122 e NIR ≤ 691.548872 e Mínimo em B ≤ 219 então Telha_Fibr_Escura | (17.0/1.0) |
| 5 | Se G > 273.720207 e MDSn > 133.947014 e 262.875274 < B ≤ 326.195122 e NIR ≤ 691.548872 e Mínimo em B > 219 então Telha_Fibr_Clara | (3.0/1.0) |
| 6 | Se G > 273.720207 e MDSn > 133.947014 e B ≤ 326.195122 e NIR > | (3.0) |

| | | |
|----|--|-----------|
| | 691.548872 e Tx. Média em R <= 289.890978 e Máximo em B <= 316 então Telha_Cer_Clara | |
| 7 | Se G > 273.720207 e MDSn > 133.947014 e B <= 326.195122 e NIR > 691.548872 e Tx. Média em R <= 289.890978 e Máximo em B > 316 então Telha_Cer_Escura | (8.0/1.0) |
| 8 | Se G > 273.720207 e MDSn > 133.947014 e B <= 326.195122 e NIR > 691.548872 e Tx. Média em R > 289.890978 e Mínimo em B <= 246 então Telha_Cer_Clara | (23.0) |
| 9 | Se G > 273.720207 e MDSn > 133.947014 e B <= 326.195122 e NIR > 691.548872 e Tx. Média em R > 289.890978 e Mínimo em B > 246 então Telha_Cer_Escura | (3.0/1.0) |
| 10 | Se G > 273.720207 e MDSn > 133.947014 e B > 326.195122 e Tx. Média em R <= 375.099632 então Telha_Fibr_Clara | (31.0) |
| 11 | Se G > 273.720207 e MDSn > 133.947014 e B > 326.195122 e Tx. Média em R > 375.099632 então Telha_Cer_Clara | (8.0) |

QUADRO 14 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 3-A

| Regra | | Cer. Escura: 229 | | Cer. Clara: 128 | | Fib. Escura: 156 | | Fibr. Clara: 83 | | Corretos | | Incorretos | |
|-------------------|--------------|------------------|------|-----------------|------|------------------|-----|-----------------|-----|----------|------|------------|-----|
| 1 | Cer. Escura | 11 | (1) | 0 | 0 | 1 | 0 | 0 | 0 | 11 | (1) | 1 | 0 |
| 2 | Fibr. Escura | 16 | 0 | 0 | 0 | 27 | (4) | 0 | 0 | 27 | (4) | 16 | 0 |
| 3 | Cer. Escura | 137 | (10) | 6 | (4) | 21 | (3) | 0 | 0 | 137 | (10) | 27 | (7) |
| 4 | Fibr. Escura | 22 | (1) | 1 | (1) | 50 | (5) | 6 | (1) | 50 | (5) | 29 | (3) |
| 5 | Fibr. Clara | 3 | 0 | 0 | 0 | 18 | (7) | 4 | (1) | 4 | (1) | 21 | (7) |
| 6 | Cer. Clara | 4 | (2) | 6 | (3) | 0 | 0 | 0 | 0 | 6 | (3) | 4 | (2) |
| 7 | Cer. Escura | 15 | (5) | 31 | (11) | 0 | 0 | 0 | 0 | 15 | (5) | 15 | (5) |
| 8 | Cer. Clara | 4 | (2) | 45 | (14) | 0 | 0 | 0 | 0 | 45 | (14) | 4 | (2) |
| 9 | Cer. Escura | 2 | (2) | 10 | (5) | 0 | 0 | 0 | 0 | 2 | (2) | 2 | (2) |
| 10 | Fibr. Clara | 0 | 0 | 12 | (4) | 11 | (4) | 49 | (6) | 49 | (6) | 23 | (8) |
| 11 | Cer. Clara | 0 | 0 | 8 | (5) | 3 | (1) | 18 | (4) | 8 | (5) | 21 | (5) |
| Identificados | | 214 | 23 | 119 | 47 | 131 | 24 | 77 | 12 | | | | |
| Corretos | | 165 | 18 | 59 | 22 | 77 | 9 | 53 | 7 | 354 | 56 | | |
| Incorretos | | 49 | 5 | 60 | 25 | 54 | 15 | 19 | 14 | 59.40% | | 163 | 41 |
| Não Identificados | | 15 | | 9 | | 25 | | 6 | | | | | |

$AI_{\text{Cer. Escura}} = 58.95\%$
 $AI_{\text{Cer. Clara}} = 30.47\%$
 $AI_{\text{Fib. Escuro}} = 36.54\%$
 $AI_{\text{Fib. Claro}} = 24.10\%$

TABELA 07 – RESULTADOS DO EXPERIMENTO 3-A

7.6.3.1.1. Análise dos resultados do Experimento 3-A

No Experimento 3-A foram geradas 11 regras para edificações. Diferentemente dos Experimentos 1 e 2, a árvore de decisão iniciou separando as amostras pela Média na Banda G (AVGBAND_4), no valor de 273,720207. A classes

referentes as quatro tipos de Telhas, bem como Asfalto, Pav_Cimentado e Gramado, possuem valores acima deste. Já as classes Árvore, Sombra e Fundo, possuem valores abaixo. Apenas duas edificações da classe Telha Cerâmica Escura, cujos telhados eram muito escuros, apresentaram valor abaixo de 273,720207, constituindo a Regra 1 deste experimento. Na divisão em que $AVGBAND_4 > 273,720207$ se encontram as classe de Telhas, e se seguiu com a utilização do MDSn ($AVGBAND_2$) com valor de cisão de 133.947014 cm. Assim, as classes de Telhas, por apresentarem valor acima deste, foram separadas das classes de Pav_Cimentado, Asfalto e Gramado. O NDVI ($BANDRATIO$) separou Gramado de Pavimentações.

Com as edificações separadas, observou-se que a Média na Banda B ($AVGBAND_3$) separou a maioria das feições da classe Telha Fibrocimento Claro. Posteriormente, a Média na Banda do NIR ($AVGBAND_5$) separou a maioria das feições da classe Telha Cerâmica Clara.

A Matriz de Confusão mostrou confusão entre as classes Telha Cerâmica Escura e Telha Cerâmica Clara maior que a confusão entre as classes Telha de Fibrocimento Escura e Telha de Fibrocimento Claro.

Foram geradas mais de uma regra para cada uma das classes de telhado, mas, dentre estas, existem regras que obtiveram maior número de acertos em cada classe. As regras 3, 4, 8 e 10, obtiveram maior número de acertos para as classes Telha Cerâmica Escura, Telha Fibrocimento Escuro, Telha Cerâmica Clara e Telha Fibrocimento Claro, respectivamente, sendo condizente com o desempenho destas regras frente às suas amostras na árvore de decisão (observar a terceira coluna do Quadro 14). Nenhuma das regras referentes às edificações fez uso de atributos de forma.

7.6.3.2. Experimento 3-B

Experimentos com atributos de textura calculados sobre a banda R, considerando dois tipos de telhado: Telhado Cerâmico e Telhado de Fibrocimento. A árvore de decisão e sua respectiva matriz confusão, gerados no Weka, são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|--|------------|
| 1 | Se G ≤ 273.720207 e Mínimo em B > 0 e NIR ≤ 572.239761 e Matiz > 215.544537 então Telha_Ceramica | (2.0) |
| 2 | Se G > 273.720207 e MDSn > 133.947014 e NIR ≤ 745.526882 e B ≤ 262.875274 e Tx. Média em R ≤ 143.832705 então Telha_Fibrocimento | (8.0/1.0) |
| 3 | Se G > 273.720207 e MDSn > 133.947014 e NIR ≤ 745.526882 e B ≤ 262.875274 e Tx. Média em R > 143.832705 então Telha_Ceramica | (41.0) |
| 4 | Se G > 273.720207 e MDSn > 133.947014 e NIR ≤ 745.526882 e 262.875274 < B ≤ 402.222222 então Telha_Fibrocimento | (33.0/1.0) |
| 5 | Se G > 273.720207 e MDSn > 133.947014 e B ≤ 402.222222 e NIR > 745.526882 então Telha_Ceramica | (42.0) |
| 6 | Se G > 273.720207 e MDSn > 133.947014 e B > 402.222222 então Telha_Fibrocimento | (18.0) |

QUADRO 15 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 3-B

| Regra | | Cerâmica: 357 | | Fibrocimento: 239 | | Corretos | | Incorretos | |
|-------------------|--------------|---------------|------|-------------------|-----|----------|------|------------|------|
| 1 | Cerâmica | 11 | (2) | 1 | 0 | 11 | (2) | 1 | 0 |
| 2 | Fibrocimento | 16 | (1) | 24 | (4) | 24 | (4) | 16 | (1) |
| 3 | Cerâmica | 152 | (16) | 22 | (4) | 152 | (16) | 22 | (4) |
| 4 | Fibrocimento | 39 | (10) | 112 | (4) | 112 | (4) | 39 | (10) |
| 5 | Cerâmica | 122 | (16) | 1 | (1) | 122 | (16) | 1 | (1) |
| 6 | Fibrocimento | 0 | 0 | 51 | (4) | 51 | (4) | 0 | 0 |
| Identificados | | 340 | 45 | 211 | 17 | | | | |
| Corretos | | 285 | 34 | 187 | 12 | 472 | (46) | | |
| Incorretos | | 55 | 11 | 24 | 5 | 79.19% | | 79 | (16) |
| Não Identificados | | 17 | | 28 | | | | | |

$$AI_{\text{Cerâmica}} = 77.87\%$$

$$AI_{\text{Fibrocimento}} = 66.95\%$$

TABELA 08 – RESULTADOS DO EXPERIMENTO 3-B

7.6.3.2.1. Análise dos resultados do Experimento 3-B

A árvore de decisão do Experimento 3-B inicia com o atributo de Média na Banda G (AVGBAND_4), também com o valor de 273,720207, pois as amostras eram as mesmas do Experimento 3-A. A estrutura da árvore do Experimento 3-B é similar à estrutura da árvore do Experimento 3-A, principalmente ao se observar as partições ocorridas para classes que não se referem a edificações. Utilizou-se do

atributo de Textura Média em R (TX_MEAN) para separar algumas feições da classe Telha Fibrocimento da classe Telha Cerâmica.

Dentre as 6 regras que levam à classificação de edificações, as Regras 3 e 5 obtêm elevado número de acertos para a classe Telha Cerâmica ao identificarem 152 e 122 edificações respectivamente, sendo condizentes com o desempenho prévio na árvore de decisão. Já a classe Telha Fibrocimento possui maior número de acertos nas Regras 4 e 6, e também concordam com o desempenho na árvore de decisão.

7.6.3.3. Experimento 3-C

Experimentos com atributos de textura calculados sobre a banda R, considerando apenas a classe Edificação, independente do tipo de telhado. A árvore de decisão e sua respectiva matriz confusão, gerados no Weka, são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|---|-------------|
| Única | Se $G > 273.720207$ e $MDSn > 133.947014$ então Edificacao | (142.0/1.0) |

QUADRO 16 – REGRA REFERENTE À EDIFICAÇÃO NO EXPERIMENTO 3-C

| Regra | | Edificação: 596 | | Corretos | | Incorretos | |
|-------|-------------------|-----------------|---|----------|---|------------|---|
| U | Edificação | 570 | 0 | 570 | 0 | 0 | 0 |
| | Identificados | 570 | 0 | | | | |
| | Corretos | 570 | 0 | 570 | 0 | | |
| | Incorretos | 0 | 0 | 95.64% | | 0 | 0 |
| | Não Identificados | 26 | | | | | |

$$AI_{\text{Edificação}} = 95.64\%$$

TABELA 09 – RESULTADOS DO EXPERIMENTO 3-C

7.6.3.3.1. Análise dos resultados do Experimento 3-C

O Experimento 3-C, onde há apenas a classe EDIFICACAO referente às edificações, sem qualquer distinção de tipos de telhado, apresentou a menor árvore de decisão, sendo mais eficiente. Apenas com a Média na Banda G (AVGBAND_4), seguido do MDSn (AVGBAND_2), se chega à classe EDIFICACAO. O resultado da aplicação desta regra identificou 570 edificações dentre as 596 existentes. O NDVI (BANDRATIO) separou os gramados das pavimentações. Nenhum atributo de textura ou de forma foi considerado.

7.6.4. Experimentos 4 (Banda 1 = NIR)

Estes experimentos possuem atributos de textura calculados sobre a banda NIR, o infravermelho próximo.

7.6.4.1. Experimento 4-A

Experimentos com atributos de textura calculados sobre a banda NIR, considerando quatro tipos de telhado: Telhado Fibrocimento Claro, Telhado Fibrocimento Escuro, Telhado Cerâmico Claro, Telhado Cerâmico Escuro. A árvore de decisão e sua respectiva matriz confusão, gerados no Weka, são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|--|-----------|
| 1 | Se 205.299251 < MDSn <= 1050.652926 e G > 248.250812 e B <= 260.625 e NIR <= 136.297125 então Telha_Fibr_Escuro | (7.0/1.0) |
| 2 | Se 205.299251 < MDSn <= 1050.652926 e G > 248.250812 e B <= 260.625 e NIR > 136.297125 então Telha_Cer_Escuro | (40.0) |

| | | |
|----|--|------------|
| 3 | Se 205.299251 < MDSn <= 1050.652926 e NIR <= 201.547619 e G > 248.250812 e B > 260.625 e Desv. Pad de NIR <= 64.444422 então Telha_Fibr_Clara | (2.0) |
| 4 | Se 205.299251 < MDSn <= 1050.652926 e NIR <= 201.547619 e G > 248.250812 e B > 260.625 e Desv. Pad de NIR > 64.444422 então Telha_Fibr_Escuro | (19.0/1.0) |
| 5 | Se 205.299251 < MDSn <= 1050.652926 e NIR > 201.547619 e B <= 326.09899 e Tx. Média em NIR <= 865.987402 e Dir. Principal <= 119.987928 então Telha_Cer_Escura | (6.0) |
| 6 | Se 205.299251 < MDSn <= 1050.652926 e NIR > 201.547619 e B <= 326.09899 e Tx. Média em NIR <= 865.987402 e Dir. Principal > 119.987928 e Comp. Eixo Menor <= 9.061005 então Telha_Cer_Clara | (5.0) |
| 7 | Se 205.299251 < MDSn <= 1050.652926 e NIR > 201.547619 e B <= 326.09899 e Tx. Média em NIR <= 865.987402 e Dir. Principal > 119.987928 e Comp. Eixo Menor > 9.061005 então Telha_Cer_Escura | (2.0) |
| 8 | Se MDSn <= 1050.652926 e NIR > 201.547619 e B <= 326.09899 e Tx. Média em NIR > 865.987402 e Entr. Tx. em NIR <= 0.193865 então Telha_Cer_Clara | (22.0) |
| 9 | Se MDSn <= 1050.652926 e NIR > 201.547619 e B <= 326.09899 e Tx. Média em NIR > 865.987402 e Entr. Tx. em NIR > 0.193865 então Telha_Cer_Escura | (3.0/1.0) |
| 10 | Se MDSn <= 1050.652926 e NIR > 201.547619 e B > 326.0989 e Tx. Média em NIR <= 970.10269 então Telha_Fibr_Clara | (27.0) |
| 11 | Se MDSn <= 1050.652926 e NIR > 201.547619 e B > 326.09899 e Tx. Média em NIR > 970.10269 então Telha_Cer_Clara | (7.0) |
| 12 | Se MDSn > 1050.652926 e Entr. Tx. em NIR > 0.193114 então Telha_Fibr_Clara | (2.0) |

QUADRO 17 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 4-A

| Regra | Cer. Escura: 229 | | Cer. Clara: 128 | | Fib. Escura: 156 | | Fib. Clara: 83 | | Corretos | | Incorretos | |
|--------------------------|------------------|-----------|-----------------|-----------|------------------|-----------|----------------|----------|---------------|-------------|------------|-------------|
| 1 Fibr. Escura | 16 | (4) | 0 | 0 | 32 | (3) | 0 | 0 | 32 | 3 | 16 | 4 |
| 2 Cer. Escura | 146 | (10) | 1 | 0 | 21 | (3) | 0 | 0 | 146 | 10 | 22 | 3 |
| 3 Fibr. Clara | 1 | (1) | 0 | 0 | 0 | 0 | 1 | 0 | 1 | 0 | 1 | 1 |
| 4 Fibr. Escura | 23 | (2) | 2 | (1) | 76 | (6) | 8 | (1) | 76 | 6 | 33 | 4 |
| 5 Cer. Escura | 18 | (4) | 31 | (5) | 0 | 0 | 0 | 0 | 18 | 4 | 31 | 5 |
| 6 Cer. Clara | 6 | (2) | 16 | (6) | 0 | 0 | 0 | 0 | 16 | 6 | 6 | 2 |
| 7 Cer. Escura | 3 | (1) | 9 | (1) | 0 | 0 | 1 | 0 | 3 | 1 | 10 | 1 |
| 8 Cer. Clara | 1 | 0 | 44 | (13) | 0 | 0 | 0 | 0 | 44 | 13 | 1 | 0 |
| 9 Cer. Escura | 1 | (1) | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 0 | 0 |
| 10 Fibr. Clara | 0 | 0 | 9 | (4) | 10 | (4) | 50 | (4) | 50 | 4 | 19 | 8 |
| 11 Cer. Clara | 0 | 0 | 5 | (4) | 2 | (1) | 13 | (3) | 5 | 4 | 15 | 4 |
| 12 Fibr. Clara | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 1 | 0 | 0 | 0 |
| Identificados | 215 | 25 | 117 | 34 | 141 | 17 | 74 | 8 | | | | |
| Corretos | 168 | 16 | 65 | 23 | 108 | 9 | 52 | 4 | 393 | (52) | | |
| Incorretos | 47 | 9 | 52 | 11 | 33 | 8 | 22 | 4 | 65.94% | | 154 | (32) |
| Não Identificados | 14 | | 11 | | 15 | | 9 | | | | | |

$AI_{\text{Cer. Escura}} = 51.97\%$
 $AI_{\text{Cer. Clara}} = 42.19\%$
 $AI_{\text{Fib. Escura}} = 47.44\%$
 $AI_{\text{Fib. Clara}} = 49.40\%$

TABELA 10 – RESULTADOS DO EXPERIMENTO 4-A

7.6.4.1.1. Análise dos resultados do Experimento 4-A

No Experimento 4-A foram geradas 12 regras para edificações. A árvore de decisão iniciou a divisão de amostras considerando a média de altura dos segmentos, o MDSn (AVGBAND_2) no valor de 205,299251 cm, que separou a amostra entre as classes relativas a feições acima do solo – como Telhado e Árvore –, e as classes relativas a feições ao nível do solo – como Pav.Cimentado, Gramado e Asfalto. Posteriormente, na subdivisão das amostras acima do solo, há ainda outra divisão entre feições mais altas que 1050,652926 cm e mais baixas que 1050,652926 cm, pois na amostra havia árvores altas e prédios altos com telhado de fibrocimento claro.

Nas feições ao nível do solo, a média na banda G (AVGBAND_4) separou as classes de Pav. Cimentado e Asfalto das classes de Gramado, Sombra e Fundo. Posteriormente a Média de Textura na banda G separou Pav. Cimentado e Asfalto. A classe Fundo distinguiu-se da classe Sombra pelo valor Mínimo na Banda B, que era igual a 0 (zero). O NDVI (BANDRATIO) separou o gramados das pavimentações e asfaltos.

Nas feições acima do solo, a Média na Banda do NIR (AVGBAND_5) separou as feições de telhas escuras das telhas claras. Assim, a maioria das feições das classes Telha Cerâmica Escura e Telha Fibrocimento Escuro apresentou valor inferior a 201,547619, bem como a maioria das feições das classes Telhas Cerâmica Clara e Telha Fibrocimento Clara apresentou valor superior a 201,547619. Após esta divisão foram utilizados outros atributos na árvore de decisão, mas nenhum conseguiu realizar a separação de alguma classe específica.

Foram geradas mais de uma regra para cada uma das classes de telhado, mas, dentre estas, existem regras que obtiveram maior número de acertos em cada classe. As regras 2, 4, 8 e 10 obtiveram maior número de acertos nas classes Telha Cerâmica Escura, Telha Fibrocimento Escura, Telha Cerâmica Clara e Telha Fibrocimento Claro, respectivamente. Esta quantidade de acertos obtida é condizente com o desempenho destas frente às suas amostras na árvore de decisão, como se observa na terceira coluna do Quadro 17. Nenhuma destas regras com elevada quantidade de acertos levou em consideração atributos de forma ou de textura.

7.6.4.2. Experimento 4-B

Experimentos com atributos de textura calculados sobre a banda NIR, considerando dois tipos de telhado: Telhado Cerâmico e Telhado de Fibrocimento. A árvore de decisão e sua respectiva matriz confusão, gerados no Weka, são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|---|------------|
| 1 | Se 205.299251 < MDSn <= 332.840439 e NIR > 109.255917 e Matiz <= 237.389308 e B <= 344 então Telha_Fibrocimento | (4.0/1.0) |
| 2 | Se MDSn > 332.840439 e NIR > 109.255917 e Matiz <= 237.389308 e B <= 344 então Telha_Ceramica | (35.0/1.0) |
| 3 | Se MDSn > 205.299251 e NIR > 109.255917 e Matiz <= 132.077778 e B > 344 então Telha_Ceramica | (8.0) |
| 4 | Se MDSn > 205.299251 e NIR > 109.255917 e Máximo em B > 344 e 132.077778 < Matiz <= 237.389308 e B <= 260.625 e Máximo em NIR <=314 então Telha_Fibrocimento | (5.0/1.0) |
| 5 | Se MDSn > 205.299251 e NIR > 109.255917 e Máximo em B > 344 e 132.077778 < Matiz <= 237.389308 e B <= 260.625 e Máximo em NIR > 314 então Telha_Ceramica | (11.0) |
| 6 | MDSn > 205.299251 e NIR > 109.255917 e Máximo em B > 344 e 132.077778 < Matiz <= 237.389308 e B > 260.625 e Tx. Média em NIR <= 927.57129 então Telha_Fibrocimento | (48.0) |
| 7 | Se MDSn > 205.299251 e NIR > 109.255917 e Máximo em B > 344 e 132.077778 < Matiz <= 237.389308 e B > 260.625 e Tx. Média em NIR > 927.57129 então Telha_Ceramica | (2.0) |
| 8 | Se MDSn > 205.299251 e NIR > 109.255917 e Matiz > 237.389308 então Telha_Ceramica | (30.0) |

QUADRO 18 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 4-B

| Regra | | Cerâmica: 357 | | Fibrocimento: 239 | | Corretos | | Incorretos | |
|-------------------|--------------|---------------|------|-------------------|------|----------|------|------------|------|
| 1 | Fibrocimento | 23 | (4) | 16 | (2) | 16 | (2) | 23 | (4) |
| 2 | Cerâmica | 89 | (13) | 13 | (4) | 89 | (13) | 13 | (4) |
| 3 | Cerâmica | 18 | (4) | 0 | 0 | 18 | (4) | 0 | 0 |
| 4 | Fibrocimento | 12 | (2) | 14 | (2) | 14 | (2) | 12 | (2) |
| 5 | Cerâmica | 48 | (6) | 21 | (2) | 48 | (6) | 21 | (2) |
| 6 | Fibrocimento | 34 | (5) | 141 | (12) | 141 | (12) | 34 | (5) |
| 7 | Cerâmica | 2 | (1) | 15 | (5) | 2 | (1) | 15 | (5) |
| 8 | Cerâmica | 119 | (16) | 1 | 0 | 119 | (16) | 1 | 0 |
| Identificados | | 345 | (51) | 221 | (27) | | | | |
| Corretos | | 276 | (40) | 171 | (16) | 447 | (56) | | |
| Incorretos | | 69 | (11) | 50 | (11) | 75.00% | | 119 | (22) |
| Não Identificados | | 12 | | 18 | | | | | |

$$AI_{\text{Cerâmica}} = 66.67\% \quad AI_{\text{Fibrocimento}} = 50.21\%$$

TABELA 11 – RESULTADOS DO EXPERIMENTO 4-B

7.6.4.2.1. Análise dos resultados do Experimento 4-B

O Experimento 4-B possui apenas a distinção de classe de Telhas de Fibrocimento e Telhado Cerâmico, sem distinção de tonalidade clara ou escura. A árvore de decisão iniciou pelo atributo MDSn (AVGBAND_2) com o valor de 205,299251 cm, separando as feições acima do solo das feições ao nível do solo.

Nas feições ao nível do solo, a Média na Banda G (AVGBAND_4) separou classes escuras como Sombra e Fundo, das classes Gramados, Pavimento Cimentado e Asfalto. Posteriormente o NDVI separou a classe Gramados.

Nas feições acima do solo as classes de Telhas, referente às edificações, foram separadas das classes Arvore e Sombra através da Média na Banda R. Assim, através do MDSn e da Média na Banda R, separou-se todas as edificações. Nesta partição da amostra se encontram as regras para as edificações e, dentre estas, destacam-se as Regras 2 e 8 para Telha Cerâmica e a Regra 6 para Telha Fibrocimento. Em nenhuma das regras referentes à edificação há a consideração de atributos de forma, apenas espectrais e de textura. Ainda assim, o atributo Textura Média em NIR (TX_MEAN) só foi considerado após várias partições na amostra, sendo menos significativo.

7.6.4.3. Experimento 4-C

Experimentos com atributos de textura calculados sobre a banda NIR, considerando apenas a classe Edificação, independente do tipo de telhado. A árvore de decisão e matriz confusão, gerados no Weka, são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|---|-------------|
| Única | Se MDSn > 205.299251 e NIR > 109.255917 então Edificacao | (143.0/1.0) |

QUADRO 19 – REGRA REFERENTE À EDIFICAÇÃO NO EXPERIMENTO 4-C

| Regra | Edificação: 596 | Corretos | Incorretos |
|--------------------------|-----------------|----------|------------|
| U | | | |
| Edificação | 592 0 | 592 0 | 0 0 |
| Identificados | 592 0 | | |
| Corretos | 592 0 | 592 0 | |
| Incorretos | 0 0 | 99.33% | 0 0 |
| Não Identificados | 4 | | |

$$AI_{\text{Edificação}} = 99.33\%$$

TABELA 12 – RESULTADOS DO EXPERIMENTO 4-C

7.6.4.3.1. Análise dos resultados do Experimento 4-C

Como vêm ocorrendo nos experimento tipo C, observa-se que com apenas dois atributos é possível definir a classe EDIFICAÇÃO e, neste experimento 4-C, estes atributos foram o MDSn (AVGBAND_2) e a média na banda R (AVGBAND_4). O resultado da aplicação desta regra identificou 592 edificações dentre as 596 existentes. O MDSn separou as feições ao nível do solo de feições acima do solo. O NDVI, nas feições ao nível do solo, separou os gramados das pavimentações. Novamente nenhum atributo de textura ou de forma foi considerado.

7.6.5. Experimentos 5 (Banda 1 = MDSn)

Estes experimentos possuem atributos de textura calculados sobre a banda MDSn, o Modelo Digital de Superfície Normalizado.

7.6.5.1. Experimento 5-A

Experimentos com atributos de textura calculados sobre a banda MDSn, considerando quatro tipos de telhado: Telhado Fibrocimento Claro, Telhado Fibrocimento Escuro, Telhado Cerâmico Claro, Telhado Cerâmico Escuro. A árvore de decisão e matriz confusão, gerados no Weka, são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|--|-----------|
| 1 | Se 234.69207 < MDSn <= 1058.640447 e NDVI <= 0.489969 e NIR <= 831.040541 e Matiz <= 261.186445 então Telha_Fibr_Claro | (29.0) |
| 2 | Se 234.69207 < MDSn <= 1058.640447 e NDVI <= 0.489969 e NIR <= 831.040541 e Matiz > 261.186445 então Telha_Cer_Escura | (2.0) |
| 3 | Se 234.69207 < MDSn <= 1058.640447 e NDVI <= 0.489969 e NIR > 831.040541 e Máximo em R <= 402 então Telha_Fibr_Claro | (4.0/1.0) |
| 4 | Se 234.69207 < MDSn <= 1058.640447 e NDVI <= 0.489969 e NIR > 831.040541 e Máximo em R > 402 e Compacidade <= 0.202906 e R <= 358.969849 então Telha_Cer_Clara | (3.0) |
| 5 | Se 234.69207 < MDSn <= 1058.640447 e NDVI <= 0.489969 e NIR > 831.040541 e Máximo em R > 402 e Compacidade <= 0.202906 e R > 358.969849 então Telha_Cer_Escura | (2.0) |
| 6 | Se 234.69207 < MDSn <= 1058.640447 e NDVI <= 0.489969 e NIR > 831.040541 e Máximo em R > 402 e Compacidade > 0.202906 então Telha_Cer_Clara | (26.0) |
| 7 | Se 234.69207 < MDSn <= 1058.640447 e NDVI > 0.489969 e G > 247.629717 e B <= 267.343284 e R <= 146.820896 e Área <= 82.125 então Telha_Cer_Escura | (2.0) |
| 8 | Se 234.69207 < MDSn <= 1058.640447 e NDVI > 0.489969 e G > 247.629717 e B <= 267.343284 e R <= 146.820896 e Área > 82.125 então Telha_Fibr_Escuro | (7.0) |
| 9 | Se 234.69207 < MDSn <= 1058.640447 e NDVI > 0.489969 e G > 247.629717 e B <= 267.343284 e R > 146.820896 e NIR <= 699.190154 então Telha_Cer_Escura | (41.0) |
| 10 | Se 234.69207 < MDSn <= 1058.640447 e NDVI > 0.489969 e G > 247.629717 e B <= 267.343284 e R > 146.820896 e NIR > 699.190154 e Alongamento <= 1.752678 então Telha_Cer_Escura | (2.0) |

| | | |
|----|---|-----------|
| 11 | Se 234.69207 < MDSn <= 1058.640447 e NDVI > 0.489969 e G > 247.629717 e B <= 267.343284 e R > 146.820896 e NIR > 699.190154 e Alongamento > 1.752678 então Telha_Cer_Clara | (3.0) |
| 12 | Se 234.69207 < MDSn <= 1058.640447 e NDVI > 0.489969 e G > 247.629717 e B > 267.343284 e Saturação <= 0.172324 e Compacidade <= 0.188201 então Telha_Cer_Clara | (2.0/1.0) |
| 13 | Se 234.69207 < MDSn <= 1058.640447 e NDVI > 0.489969 e G > 247.629717 e B > 267.343284 e Saturação <= 0.172324 e Compacidade > 0.188201 e Dir. Principal <= 144.347338 então Telha_Cer_Escura | (5.0) |
| 14 | Se 234.69207 < MDSn <= 1058.640447 e NDVI > 0.489969 e G > 247.629717 e B > 267.343284 e Saturação <= 0.172324 e Compacidade > 0.188201 e Dir. Principal > 144.347338 então Telha_Cer_Clara | (2.0) |
| 15 | Se 234.69207 < MDSn <= 1058.640447 e NDVI > 0.489969 e G > 247.629717 e B > 267.343284 e Saturação > 0.172324 e Desv. Pad em MDSn <= 100.421798 então Telha_Fibr_Escuro | (17.0) |
| 16 | Se 234.69207 < MDSn <= 1058.640447 e NDVI > 0.489969 e G > 247.629717 e B > 267.343284 e Saturação > 0.172324 e Desv. Pad em MDSn > 100.421798 então Telha_Fibr_Claro | (4.0/1.0) |
| 17 | Se 234.69207 < MDSn <= 1058.640447 e Dir. Principal <= 27.593415 então Telha_Fibr_Claro | (2.0) |

QUADRO 20 – REGRAS REFERENTES À EDIFICAÇÃO NO EXPERIMENTO 5-A

| Regra | | Cer. Escura: 229 | | Cer. Clara: 128 | | Fib. Escuro: 156 | | Fib. Claro: 83 | | Corretos | | Incorretos | |
|-------------------|--------------|------------------|------|-----------------|------|------------------|------|----------------|-----|----------|------|------------|------|
| 1 | Fibr. Claro | 7 | (3) | 6 | (4) | 14 | (4) | 33 | (2) | 33 | (2) | 27 | (11) |
| 2 | Cer. Escura | 7 | (2) | 5 | (2) | 0 | 0 | 0 | 0 | 7 | (2) | 5 | (2) |
| 3 | Fibr. Claro | 1 | (1) | 6 | (2) | 0 | 0 | 1 | (1) | 1 | (1) | 7 | (3) |
| 4 | Cer. Clara | 0 | 0 | 8 | (4) | 0 | 0 | 1 | 0 | 8 | (4) | 1 | 0 |
| 5 | Cer. Escura | 2 | (2) | 4 | (1) | 2 | (1) | 2 | (1) | 2 | (2) | 8 | (3) |
| 6 | Cer. Clara | 1 | (1) | 43 | (8) | 2 | (1) | 15 | (2) | 43 | (8) | 18 | (4) |
| 7 | Cer. Escura | 6 | (5) | 0 | 0 | 9 | (2) | 0 | 0 | 6 | (5) | 9 | (2) |
| 8 | Fibr. Escuro | 18 | (3) | 0 | 0 | 39 | (2) | 0 | 0 | 39 | (2) | 18 | (3) |
| 9 | Cer. Escura | 162 | (10) | 1 | 0 | 14 | (2) | 0 | 0 | 162 | (10) | 15 | (2) |
| 10 | Cer. Escura | 5 | (2) | 6 | (1) | 0 | 0 | 0 | 0 | 5 | (2) | 6 | (1) |
| 11 | Cer. Clara | 3 | (1) | 5 | (5) | 0 | 0 | 0 | 0 | 5 | (5) | 3 | (1) |
| 12 | Cer. Clara | 2 | (1) | 2 | (1) | 1 | (1) | 0 | 0 | 2 | (1) | 3 | (2) |
| 13 | Cer. Escura | 7 | (1) | 17 | (3) | 3 | (2) | 0 | 0 | 7 | (1) | 20 | (5) |
| 14 | Cer. Clara | 1 | 0 | 2 | (1) | 1 | 0 | 1 | 0 | 2 | (1) | 3 | 0 |
| 15 | Fibr. Escuro | 5 | 0 | 2 | (1) | 45 | (2) | 4 | 0 | 45 | (2) | 11 | (1) |
| 16 | Fibr. Claro | 0 | 0 | 0 | 0 | 4 | (1) | 2 | 0 | 2 | 0 | 4 | (1) |
| 17 | Fibr. Claro | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 1 | 0 | 0 | 0 |
| Identificados | | 227 | (32) | 107 | (33) | 134 | (18) | 60 | (6) | | | | |
| Corretos | | 189 | (22) | 60 | (19) | 84 | (4) | 37 | (3) | 370 | (48) | | |
| Incorretos | | 38 | (10) | 47 | (14) | 50 | (14) | 23 | (3) | 62.08% | | 158 | (41) |
| Não Identificados | | 2 | | 21 | | 22 | | 23 | | | | | |

$$AI_{\text{Cer. Escura}} = 55.90\% \quad AI_{\text{Cer. Clara}} = 41.41\% \quad AI_{\text{Fibr. Escuro}} = 49.36\% \quad AI_{\text{Fibr. Claro}} = 26.51\%$$

TABELA 13 – RESULTADOS DO EXPERIMENTO 5-A

7.6.5.1.1. Análise dos resultados do Experimento 5-A

O Experimento 5-A, onde havia quatro classes referentes às edificações, gerou 17 regras para edificações.

A árvore de decisão iniciou a divisão de amostras considerando a média de altura dos segmentos, o MDSn (AVGBAND_1), pelo valor 234,69207 cm, onde se separou a amostra entre as classes relativas a feições acima do solo – como Telhado e Árvore –, e as classes relativas a feições ao nível do solo – como Pav. Cimentado, Gramado e Asfalto. Nas amostras acima do solo há ainda outra divisão entre feições mais altas e mais baixas que 1058,640447 cm, pois na amostra havia árvores altas e prédios altos com telhado de fibrocimento claro.

Nas feições ao nível do solo, a média na banda G (AVGBAND_3) separou as classes de Pav. Cimentado e Asfalto das classes de Gramado, Sombra e Fundo. A classe Fundo distinguiu-se da classe Sombra pelo valor Mínimo na Banda B, que era igual a 0 (zero). O NDVI (BANDRATIO), novamente, separou Gramado de Pavimentação e Asfalto.

Nas feições acima do solo, o NDVI (BANDRATIO) separou as feições de telhas escuras das telha claras. Assim, a maioria das feições das classes Telha Cerâmica Escura e Telha Fibrocimento Escuro apresentou valor de NDVI inferior a 0,489969, bem como a maioria das feições das classes Telhas Cerâmica Clara e Telha Fibrocimento Clara apresentou valor de NDVI acima deste

As regras 1, 6, 9, 8 e 15 obtiveram maior número de acertos, sendo a regra 1 referente à Telha Fibrocimento Claro; a regra 6 referente à Telha Cerâmica Clara; a regra 9 referente à Telha Cerâmica Escura; e as regras 8 e 15 referentes à Telha Fibrocimento Escura. Esta quantidade de acertos obtida é condizente com o desempenho destas frente às suas amostras na árvore de decisão, como se observa na terceira coluna do Quadro 20.

Mais uma vez, os atributos de forma foram utilizados apenas quando haviam sido feitas várias partições nas amostras, pois só propiciaram maior ganho de informação quando havia poucos segmentos na amostra. Também se observa que nenhum atributo de textura foi utilizado.

7.6.5.2. Experimento 5-B

Experimentos com atributos de textura calculados sobre a banda MDSn, considerando dois tipos de telhado: Telhado Cerâmico e Telhado de Fibrocimento. A árvore de decisão e sua respectiva matriz confusão são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|--|-----------|
| 1 | Se MDSn > 234.69207 e R > 109.030008 e Matiz <= 221.505632 e Máximo em B <= 366 e Tx. Média em MDSn <= 336.011971 então Telha_Fibrocimento | (2.0) |
| 2 | Se MDSn > 234.69207 e R > 109.030008 e Matiz <= 221.505632 e Máximo em B <= 366 e Tx. Média em MDSn > 336.011971 então Telha_Ceramica | (26.0) |
| 3 | Se MDSn > 234.69207 e 109.030008 < R <= 138.408702 e Matiz <= 221.505632 e Máximo em B > 366 e B <= 259.190045 então Telha_Fibrocimento | (7.0/1.0) |
| 4 | Se MDSn > 234.69207 e 109.030008 < R <= 392.626087 e Matiz <= 221.505632 e Máximo em B > 366 e B <= 259.190045 então Telha_Ceramica | (6.0) |
| 5 | Se MDSn > 234.69207 e 259.190045 < R <= 392.626087 e Matiz <= 221.505632 e Máximo em B > 366 e NIR <= 797.660819 então Telha_Fibrocimento | (44.0) |
| 6 | Se MDSn > 234.69207 e 109.030008 < R <= 392.626087 e Matiz <= 221.505632 e Máximo em B > 366 e B > 259.190045 e NIR > 797.660819 e Saturação <= 0.164882 então Telha_Fibrocimento | (7.0) |
| 7 | Se MDSn > 234.69207 e 109.030008 < R <= 392.626087 e Matiz <= 221.505632 e Máximo em B > 366 e NIR > 797.660819 e Saturação > 0.164882 então Telha_Ceramica | (3.0) |
| 8 | Se MDSn > 234.69207 e R > 392.626087 e Matiz <= 221.505632 e Máximo em B > 366 então Telha_Ceramica | (5.0) |
| 9 | Se MDSn > 234.69207 e R > 109.030008 e Matiz > 221.505632 e Intervalo de Textura em MDSn <= 23.183603 então Telha_Fibrocimento | (2.0) |
| 10 | Se MDSn > 234.69207 e R > 109.030008 e Matiz > 221.505632 e Intervalo de Textura em MDSn > 23.183603 e Máximo em MDSn <= 452.398682 e Matiz <= 229.995186 então Telha_Fibrocimento | (2.0) |
| 11 | Se MDSn > 234.69207 e R > 109.030008 e Matiz > 221.505632 e Intervalo de Textura em MDSn > 23.183603 e Máximo em MDSn <= 452.398682 e Matiz > 229.995186 então Telha_Ceramica | (5.0) |
| 12 | Se MDSn > 234.69207 e R > 109.030008 e Matiz > 221.505632 e Intervalo de Textura em MDSn > 23.183603 e Máximo em MDSn > 452.398682 então Telha_Ceramica | (45.0) |

QUADRO 21 – RESULTADOS DO EXPERIMENTO 5-B

| Regra | | Cerâmica: 357 | | Fibrocimento: 239 | | Corretos | | Incorretos | |
|-------------------|--------------|---------------|------|-------------------|------|----------|------|------------|-----|
| 1 | Fibrocimento | 26 | (3) | 17 | (1) | 17 | (1) | 26 | (3) |
| 2 | Cerâmica | 65 | (6) | 11 | (5) | 65 | (6) | 11 | (5) |
| 3 | Fibrocimento | 1 | (1) | 24 | (1) | 24 | (1) | 1 | (1) |
| 4 | Cerâmica | 34 | (4) | 7 | (1) | 34 | (4) | 7 | (1) |
| 5 | Fibrocimento | 12 | (1) | 114 | (10) | 114 | (10) | 12 | (1) |
| 6 | Fibrocimento | 6 | (2) | 10 | (1) | 10 | (1) | 6 | (2) |
| 7 | Cerâmica | 3 | (2) | 0 | 0 | 3 | (2) | 0 | 0 |
| 8 | Cerâmica | 5 | (3) | 24 | (3) | 5 | (3) | 24 | (3) |
| 9 | Fibrocimento | 0 | 0 | 1 | (1) | 1 | (1) | 0 | 0 |
| 10 | Fibrocimento | 14 | (2) | 2 | 0 | 2 | 0 | 14 | (2) |
| 11 | Cerâmica | 31 | (4) | 2 | (1) | 31 | (4) | 2 | (1) |
| 12 | Cerâmica | 156 | (16) | 5 | (2) | 156 | (16) | 5 | (2) |
| Identificados | | 353 | (44) | 217 | (26) | | | | |
| Corretos | | 294 | (35) | 168 | (14) | 462 | 49 | | |
| Incorretos | | 59 | (9) | 49 | (12) | 77.52% | | 108 | 21 |
| Não Identificados | | 4 | | 22 | | | | | |

$$AI_{\text{Cerâmica}} = 69.75\%$$

$$AI_{\text{Fibrocimento}} = 54.81\%$$

TABELA 14 – RESULTADOS DO EXPERIMENTO 5-B

7.6.5.2.1. Análise dos resultados do Experimento 5-B

O Experimento 5-B possui apenas a distinção de classe de Telhas de Fibrocimento e Telhado Cerâmico, sem distinção de tonalidade clara ou escura, e gerou uma árvore com 12 regras para edificações. A árvore de decisão teve como atributo de maior ganho o MDSn (AVGBAND_1), com o valor de 234,69207 cm, que separou as feições acima do solo das feições ao nível do solo.

Nas feições ao nível do solo, a Média na Banda G (AVGBAND_3) separou classes escuras como Sombra e Fundo, das classes Gramados, Pavimento Cimentado e Asfalto. Posteriormente o NDVI separou a classe Gramados. Nas feições acima do solo, as classes de Telhas – referente às edificações – foram separadas das classes Arvore e Sombra através da Média na Banda R (AVGBAND_4). Assim, após esta partição, têm-se todas as classes referentes às edificações separadas das demais classes.

Na Tabela 14, dentre as 12 regras geradas referentes às edificações, destacam-se as regras 2 e 12 para Telha Cerâmica, e a Regra 5 para Telha

Fibrocimento. Em nenhuma das regras referentes às edificações há a consideração de atributos de forma, apenas espectrais ou de textura.

7.6.5.3. Experimento 5-C

Experimentos com atributos de textura calculados sobre a banda MDSn, considerando apenas a classe Edificação, independente do tipo de telhado. A árvore de decisão e sua respectiva matriz confusão são mostradas no Apêndice B.

| REGRA | DESCRIÇÃO DA REGRA | WEKA |
|-------|--|-------------|
| Única | Se MDSn > 234.69207 e R > 109.030008 então Edificacao | (154.0/1.0) |

QUADRO 22 – REGRA REFERENTE À EDIFICAÇÃO NO EXPERIMENTO 5-C

| Regra | | Edificação: 596 | | Corretos | | Incorretos | |
|-------|-------------------|-----------------|---|----------|---|------------|---|
| U | Edificação | 586 | 0 | 586 | 0 | 0 | |
| | Identificados | 586 | 0 | | | | |
| | Corretos | 586 | 0 | 586 | 0 | | |
| | Incorretos | 0 | 0 | 98.32% | | 0 | 0 |
| | Não Identificados | 10 | | | | | |

$$AI_{\text{Edificação}} = 98.32\%$$

TABELA 15 – RESULTADOS DO EXPERIMENTO 5-C


7.6.5.3.1. Análise dos resultados do Experimento 5-C

O Experimento 5-C, onde há apenas a classe EDIFICACAO referente às edificações sem qualquer distinção de tipos de telhado, apresentou a menor árvore de decisão, sendo mais eficiente. Observa-se que apenas o MDSn (AVGBAND_1), e a média na banda R (AVGBAND_4), conduzem à classe EDIFICACAO, e o resultado da aplicação desta regra identificou 586 edificações dentre as 596 existentes.

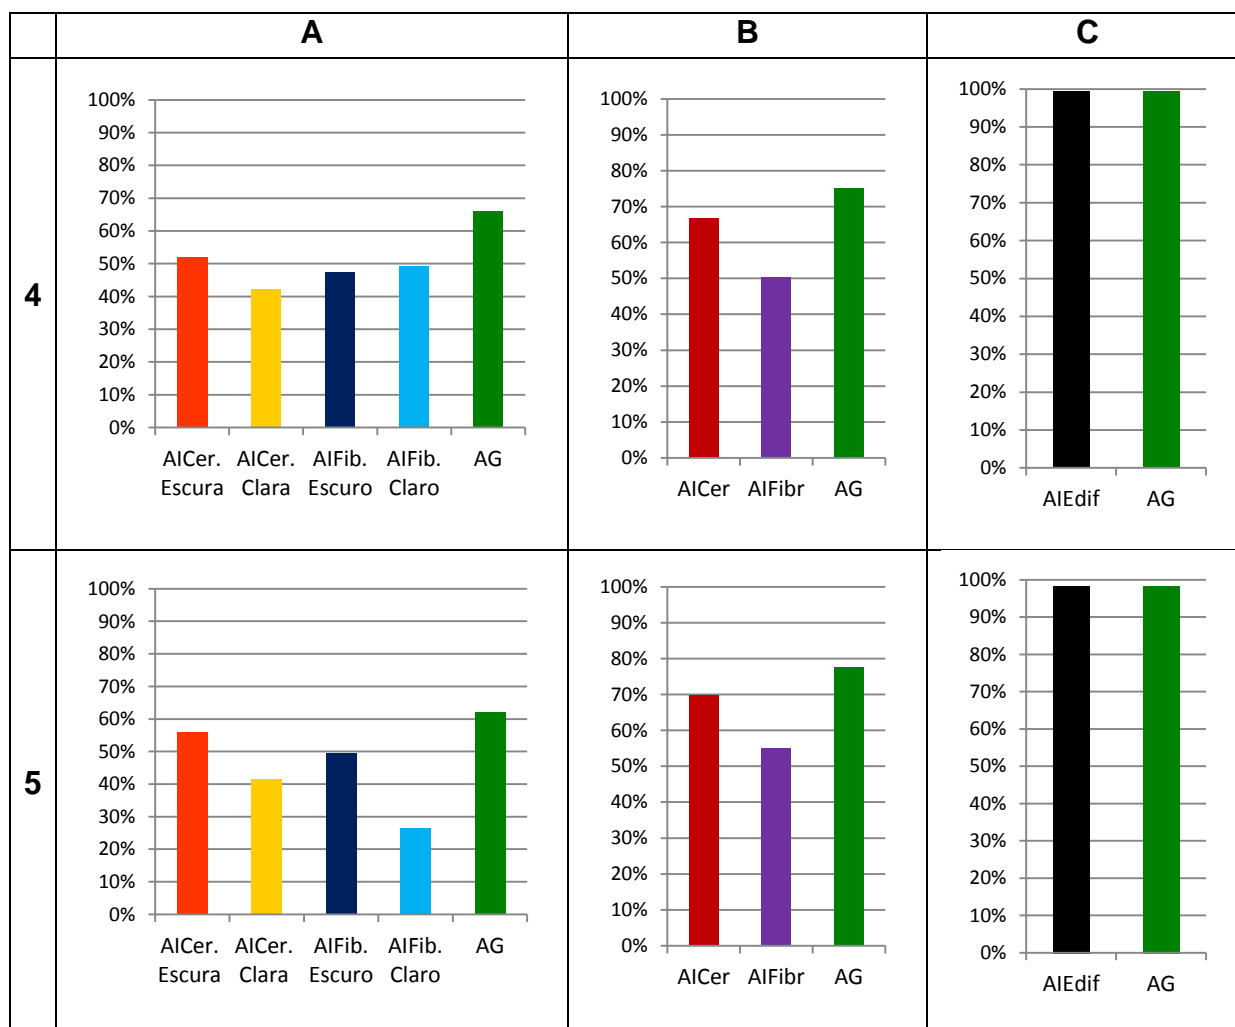
O NDVI, nas feições ao nível do solo, separou os gramados das pavimentações. O MDSn separou as feições ao nível do solo de feições acima do solo. Acima do solo, a média da banda R separou as edificações das árvores e sombras. Nenhum atributo de textura ou de forma foi considerado.

7.7. VISÃO GERAL DOS ÍNDICES DE ACURÁCIA DOS EXPERIMENTOS

Nos Quadros 23 e 24 são mostrados gráficos dos índices de acurácia calculados para cada experimento realizado.



QUADRO 23 – GRÁFICOS REPRESENTATIVOS DOS INDICES DE ACURÁCIA POR CLASSE E GLOBAL NOS EXPERIMENTOS 1, 2 e 3.



QUADRO 24 – GRÁFICOS REPRESENTATIVOS DOS ÍNDICES DE ACURÁCIA POR CLASSE E GLOBAL NOS EXPERIMENTOS 4 e 5.

Observando os gráficos percebe-se que os Experimentos tipo A, com 4 classes, obteve os menores valores para os Índices de Acurácia por classe (AI), com valores entre 20% e 60%, bem como os menores valores para o Índice de Acurácia Global (AG), com valores em torno de 60%. Nos Experimentos tipo B estes índices melhoram, apresentando valores de AI entre 50% e 80%, e valores de AG entre 70 e 80%. Já os Experimentos tipo C, que possuem apenas uma classe, apresentam os melhores resultados, com valores de AI e AG (são iguais) entre 90% e 100%.

Observa-se que os experimentos com uma maior quantidade de classes de edificações geraram resultados com índices de acurácia mais baixo. A maior quantidade de classes implica em se ter regras mais específicas, que avaliam um maior número de atributos para diferenciar feições, produzindo-se regras mais longas, mais passíveis a erros.

7.8. SÍNTESE DOS RESULTADOS

- A Transformação Projetiva apresentou bom resultado na ortorretificação da imagem, visto que a análise de resíduos obteve erro médio quadrático pouco maior que 1 pixel, com a imagem se ajustando ao MDS.
- A filtragem do MDS, executada para retirar os pixels isolados e com valores altos, existentes sobre feições como rede de energia elétrica, postes e muros (“*outliers*”), gerou bons resultados, mesmo não tendo retirado todos estes pixels. Embora o Experimento 2-B tenha utilizado o atributo de valor máximo de MDSn (MAXBAND_2) com um valor não condizente com a realidade – separando a classe Asfalto da classe Pavimento Cimentado –, os demais experimentos fizeram uso do atributo média de altura do MDSn (AVGBAND) com um valor adequado para uma classificação correta.
- O chamado Experimento Prévio, mostrado no Capítulo 6, foi realizado com base no pixel, utilizando o conhecimento do analista. Este experimento gerou bons resultados visto que identificou a maioria das edificações, ainda que em menor quantidade que os experimentos do Capítulo 7. Os experimentos realizados no Capítulo 7, por sua vez, são mais trabalhosos, pois exigem maior cuidado durante a segmentação da imagem – para não gerar segmentos mistos –, bem como dependem da coleta de amostras. Assim, frente à maior facilidade de aplicação e menor quantidade de acertos, entende-se que o então chamado Experimento Prévio, pode ser utilizado como um experimento expedito, cuja metodologia pode ser utilizada para análises de possíveis resultados antes da aplicação de métodos mais robustos.
- Os atributos de forma existem em função da segmentação da imagem e, por isso mesmo, a melhor utilização destes é dependente de uma segmentação ideal, isto é, uma segmentação tal que represente cada edificação por um e apenas um segmento. Entretanto, a complexidade de uma cena urbana de alta densidade, tendo edificações muito próximas uma das outras, com

diversas geometrias e tamanhos, bem como a atuação da iluminação solar, gera maiores dificuldades no uso dos atributos de forma como atributos capazes de caracterizar edificações.

- Um dos atributos de forma que naturalmente vem à mente ao se pensar em edificações é a Retangularidade, pois muitas edificações possuem este formato. Entretanto, este conceito de “retangularidade” é facilmente percebido pelo ser humano porque ele possui maior capacidade de abstração, podendo identificar uma forma retangular de modo mais amplo, desconsiderando detalhes de reentrâncias ou saliências no entorno da edificação, mas ainda considerá-la retangular. Ocorre que tais reentrâncias e saliências influenciam nos valores dos atributos calculados. A Figura 61 mostra algumas geometrias possíveis de serem encontradas em edificações urbanas, e que alteram sensivelmente o valor do atributo de Retangularidade, bem como de outros atributos de forma. Esta Figura 61 foi criada a partir de pequenas partes da Figura 51. Percebe-se que muitas edificações não apresentam necessariamente uma forma retangular, mas sim uma geometria composta por várias formas geométricas regulares unidas, inclusive vários retângulos. Não há um atributo que consiga mensurar esta característica de modo a permitir ao computador entender que, mesmo aquele segmento não compacto ou não exatamente retangular, mas composto por formas geométricas regulares, ainda pode ser uma edificação.




FIGURA 62 – A DIVERSIDADE DE FORMAS POSSÍVEIS DE EDIFICAÇÕES, E SEUS RESPECTIVOS SEGMENTOS, TENDE A DIFICULTAR O GANHO DE INFORMAÇÃO COM ATRIBUTOS DE FORMA.

8. CONCLUSÕES

Este trabalho teve por objetivo identificar edificações em ambiente urbano com abordagem baseada em objetos, por meio de regras obtidas com árvores de decisão em imagem menor, e buscando identificar outras edificações em uma imagem maior. Pelos experimentos realizados e pelas etapas que os antecederam, verificou-se que:

- A integração de dados oriundos de levantamentos ALS e dados de Imagens de alta resolução, foi importante em três momentos:
 - 1º) ao realizar a ortorretificação da imagem, através do uso do MDS gerado com dados ALS, constituindo o Espaço Objeto;
 - 2º) ao auxiliar o segmentador por meio do MDSn que, inserido como uma banda da imagem, melhorou a segmentação das edificações.
 - 3º) ao realizar a classificação dos segmentos gerados, onde o MDSn forneceu o atributo mais significativo em 12 dos 15 experimentos realizados, e nos outros 3 experimentos (Experimentos 3A, 3B e 3C) o MDSn foi o segundo atributo mais significativo.
- Os experimentos tipo A apresentaram menor quantidade de acertos em relação aos experimentos tipo B e C, uma vez que exigiram mais da classificação para distinguir tipos de telhados. Da mesma forma os experimentos tipo B apresentam menor quantidade de acertos que os experimentos tipo C. A maior quantidade de classes implica em se ter regras mais específicas, que avaliam um maior número de atributos para diferenciar feições, produzindo-se regras mais longas. Assim verificou-se que a menor quantidade de classe esteve relacionada à menor quantidade de regras e ao maior número de acertos.
- Dentre as regras longas e com menor quantidade de acertos, estão aquelas que consideraram atributos de forma. A consideração dos atributos de forma

só ocorreu após várias partições na amostra, ou seja, após outros atributos terem sido utilizados primeiramente para formar a regra. Assim entende-se que os atributos de forma não foram significativos, pois somente após várias partições da amostra é que foi possível se obter uma maior razão de ganho de informação com tais atributos.

- O fato dos atributos de forma não se mostrarem significativos nestes experimentos demonstra que as características de forma e tamanho das edificações na imagem tiveram pouca influência nos resultados. Já a maior proximidade das edificações entre si exerce maior influência, pois dificultam a segmentação, tendendo a gerar segmentos mistos.
- Imagens urbanas apresentam edificações de diversas formas e tamanhos, o que se torna um obstáculo à utilização dos atributos de forma como atributos significativos capazes de identificar um grande número de edificações. Tais características destas imagens restringem o potencial de utilização da análise baseada no objeto.
- Os atributos de textura, na maioria dos experimentos, não se apresentaram como atributos significativos para a identificação de edificação, com exceção do experimento 1-B, onde o atributo de textura média na banda B foi importante. Assim, tais atributos não podem ser considerados não significativos.
- Nos experimentos realizados, os atributos mais significativos foram a altura no MDSn, Média na Banda B, Média na Banda G, Média na Banda R, Média na Banda NIR, e o NDVI. Todos espectrais.
O MDSn, mesmo que possuindo o significado físico de altura do segmento, pode ser considerado como um atributo espectral, pois relaciona a maior altura ao maior valor de DN na escala de cinza da imagem. O MDSn foi o atributo mais recorrente nos experimentos realizados, separando amostras ao nível do solo das amostras acima do solo. O NDVI separou as áreas construídas das vegetações. A Média na Banda R separou feições de telha cerâmica, em especial as telhas cerâmicas clara, devido a sua tonalidade

vermelha destacada. Também, nos experimentos tipo C, separou as árvores das edificações observando os baixos valores que as árvores apresentam nesta faixa do espectro. As árvores foram separadas de outras feições também através do atributo de Média na Banda NIR, devido aos altos valores que as árvores apresentam no infravermelho próximo.

- A obtenção de bons resultados com utilização de Árvores de Decisão para geração de regras de classificação com base no objeto é dependente das amostras coletadas, e a qualidade destas amostras é dependente da segmentação realizada.
- A metodologia apresentada neste trabalho realiza a identificação de edificações utilizando-se de regras geradas por árvore de decisão a partir de amostras retiradas de uma imagem Base, menor, e que são aplicadas em uma imagem Teste, maior. A metodologia é viável, mas com restrição de que tais imagens devem possuir semelhança quanto às características espectrais das edificações.

9. RECOMENDAÇÕES

Em experimentos futuros recomenda-se:

- testar outros segmentadores visando melhorar a geometria dos segmentos gerados;
- criar árvores de decisão com outros valores para os parâmetros de configuração do algoritmo J48, bem como utilizar outros algoritmos de árvore de decisão;
- utilizar regras Fuzzy para a geração de regras de classificação, e;
- realizar testes com fotografias aéreas com banda infravermelha, uma vez que fotografias têm maior resolução espacial e sofrem menos com os efeitos de interferências atmosféricas.

10. REFERÊNCIAS BIBLIOGRÁFICAS

ANTUNES, A. F. B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. Tese (Doutorado em Ciências Geodésicas) – Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba, 2003.

ARAKI, H. **Fusão de informações espectrais, altimétricas e de dados auxiliares na classificação de imagens de alta resolução espacial**. 126p. Tese (Doutorado em Ciências Geodésicas) – Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba, 2005.

ARAKI, H., CENTENO J.A.S., HUINCA, S.C.M., CAVALHEIRO, A.C – Ortorectificação de imagem quickbird utilizando modelos geométricos dependentes de terreno e modelo de superfície gerado com dados laserscanning. In: COLÓQUIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS, 4., 2005, Curitiba. **Anais do IV Colóquio Brasileiro de Ciências Geodésicas**. Curitiba: Curso de Pós-Graduação em Ciências Geodésicas, 2005.

AWRANGJEB, M; RAVANBAKHS, M; FRASE, C.S. Automatic detection of residential buildings using LIDAR data and multispectral imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, p. 457 – 467, Sep 2010.

AZEVEDO, E.; CONCI, A. **Computação gráfica - Teoria e Prática**. Rio de Janeiro: Ed. Elsevier, 2003.

BAATZ, M.; SCHAPE, A.,. Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. In: Strobl, L.J., Blaschke T. and Griesebener T. (Eds.), *Angewandte geographische informationsverarbeitung XII, Beitrage zum AGIT Symposium Salzburg 2000*. Herbert Wichmann Verlag, Heidelberg, pp. 12-23, 2000

BITTENCOURT, G. **Inteligência artificial**. Florianópolis: Ed. da UFSC, 2001.

BOCCARDO, P.; MONDINO, E. B.; TONOLO, F. G.; LINGUA, A. Orthorectification of high resolution satellite images. In: **ISPRS Congress, 2004**, Istanbul: IAPRS, 2004. v. XXXV

BURROUGH, P. A. **Principles of Geographic Information System for Land Resources Assessment**. New York: Ed. Oxford University, 1986.

CARLEER, A.P.; DEBEIR, O.; WOLFF, E. Assessment of very high spatial resolution satellite image segmentations – **Photogrammetric Engineering & Remote Sensing**, v. 71, nº 11, p. 1285-1294, Nov 2005.

CASTRO, F. S. P.; DEBIASI, P.; CENTENO, J. A. S. Extração de estradas em imagens de intensidade laser utilizando morfologia matemática. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., Natal. **Anais XIV Simpósio Brasileiro de Ciências Geodésicas**, Natal: INPE, 2009, p. 5001 – 5007.

CENTENO, J. A. S. Identificação de prédios em imagens de altimetria obtidas usando laser scanner. In: COLÓQUIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS, 2., 2001, Curitiba. **Anais II Colóquio Brasileiro de Ciências Geodésicas**. Curitiba: Curso de Pós-Graduação em Ciências Geodésicas, 2001.

CENTENO, J. A. S. **Sensoriamento Remoto e Processamento de Imagens Digitais**. Curitiba: Ed. Curso de Pós Graduação em Ciências Geodésicas, 2009.

CRISP, D. J.; TAO, T. C. Fast region merging algorithms for image segmentation. In: **ASIAN CONFERENCE ON COMPUTER VISION, 5., 2002, Melbourne. Proceedings of the 5th Asian Conference on Computer Vision**. Melbourne, Australia: D. Suter and A. Bab-Hadiashar. Jan 2002, p. 412 – 417.

CRISP, D. J.; PERRY, P.; REDDING, N. J. Fast segmentation of large images. In: **AUSTRALASIAN COMPUTER SCIENCE CONFERENCE, 26., 2003. Proceedings of the 26th Australasian Computer Science Conference**, v. 16. Adelaide, Australia: Australian Computer Society. 2003, p. 87 – 93.

COMANICIU, D.; MEER, P. Mean shift: A robust approach toward feature space analysis. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24, n. 5, pp 603–619, 2002.

DAI, Q.; LIU, G.; WANG C., WANG L. A remote sensing image segmentation method based on spectral and structure information fusion. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**. Vol. XXXVII. Part B7, Commission VII, WG VII/6, pp 1215-1222. Beijing 2008.

DOWMAN, I.; TAO, V. An Update on the Use of Rational Functions for Photogrammetric Restitution (2002) ISPRS v. 7, n. 3, Sep 2002.

ENVI Feature Extraction Model User's Guide, 2008.

FILHO, O. M.; NETO, H. V. **Processamento Digital de Imagens**. Rio de Janeiro: Ed. Brasport, 1999.

FLOOD, M., GUTELIUS, B. Commercial implications of topographic terrain mapping using scanning airborne laser radar. **Photogrammetric Engineering and Remote Sensing**, v. 63, p. 327–329; p. 363–366, 1997.

GALO, M.; CAMARGO, P. O. **Utilização do GPS no controle da qualidade de carta**. Congresso Brasileiro de Cadastro Técnico Multifinalitário. Florianópolis, p. 41 - 48, 1994.

GEMAEL, C. **Introdução ao ajustamento de observações**. Curitiba: Ed. UFPR, 2004.

GILAT, A. **Matlab: an introduction with applications**. 1. ed. Ed. Wiley, 2003, p. 07.

GONZALEZ, R.C.; WOODS, R. **Processamento de imagens digitais**. 2. ed. São Paulo: Ed. Edgard Blüchner Ltda., 2000.

GONZALEZ, R.C.; WOODS, R. **Digital Image Processing** 3. ed. New Jersey: Ed. Prentice Hall, 2008.

GUTIERREZ, J. G.; SECO, L. G.; SANTOS, J. C. R. Decision tree on lidar to classify land uses and covers. In: LASER SCANNING, 2009, **The International Archives of the Photogrammetry**, v. XXXVIII, part 3/W8. Paris, France: Bretar F, Pierrot-Deseilligny M, Vosselman G. Sep 2009, pp. 323 – 329.

HAY, G.J., BLASCHKE, T., MARCEAU, D.J. AND BOUCHARD, A. A comparison of three image-object methods for the multiscale analysis of landscape structure. **ISPRS Journal of Photogrammetry and Remote Sensing**, 57(5-6), pp. 327-345, 2003.

IBGE – **Introdução ao processamento digital de imagens** – Manuais Técnicos em Geociências nº 9, Rio de Janeiro, 2001. p. 94.

ITT VIS (Visual Information Solutions) ENVI Feature Extraction Module 4.6 User's Guide. 2008.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. Tradução da 2ª edição, São José dos Campos, Ed. Parêntese, 2009. p. 235.

JIN, Xiaoying; DAVIS, Curt. H. Automated building extraction from high-resolution satellite imagery in urban areas using structural, contextual, and spectral information. **Journal on Applied Signal Processing**, v. 14, p. 2196-2206, 2005.

KAHOVI, Ron; QUINLAN, J. Ross. **Decision Tree Discovery Handbook of Data Mining and Knowledge Discovery**, Oxford: Ed. Oxford University, 2002. p. 267 – 276.

KIEMA J. B. K; BÄHR, H.-P. Fusion of color infrared imagery and airborne laser scanning data in automatic classification of urban environments. **Revista Brasileira de Cartografia**, v. 52, p. 29-36, 2000.

KOEPFLER G.; LOPEZ, C.; MOREL, J. M. A multiscale algorithm for image segmentation by variational method. **SIAM Journal of Numerical Analysis**, v. 31, n.1, p. 282-299, 1994.

KORTING, T. S.; FONSECA, L. M. G; ESCADA, Maria.I. S., CÂMARA, Gilberto. GeoDMA – Um sistema para mineração de dados de Sensoriamento Remoto. Simpósio Brasileiro de Sensoriamento Remoto, 14., Natal, 2009. **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto**. São José dos Campos: INPE, 2009, p. 7813 – 7820.

KÖTHE, Ullrich. Primary Image Segmentation. In: DAGM-SYMPOSIUM, 17., 1995, Bielefeld, Germany. **Proceedings**. Berlin: Springer, 1995. p. 554 – 561.

LAPOLLI, E. M.; ALVES, A. R.; BARCIA, R. M. Classificação de imagens digitais: comparação entre vários métodos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 7., 1993, Curitiba. **Anais do VII Simpósio Brasileiro de Sensoriamento Remoto**. São José dos Campos: INPE, 1993, , v. 2, p. 373 – 380.

MARTINS, Vagner A.; FONSECA, Leila M. G. Classificação de uso de solo baseada na análise orientada a objeto e mineração de dados utilizando imagens SPOT/HRG-5. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., Natal. **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto**. Natal, INPE, 2009, p. 7837 – 7844.

MATIKAINEN, L.; KAARTINEN, H.; HYYPPÄ. Classification tree based building detection from laserscanner and aerial image data. In: ISPRS WORKSHOP ON LASER SCANNING AND SILVILASER, 2007, Espoo, Finland. **Proceedings of the ISPRS Workshop Laser Scanning 2007 and SilviLaser 2007**. Espoo, Finland: P. Rönholm, H. Hyyppä, J. Hyyppä, Sep 2007, v. XXXVI, p. 280-287.

MITISHITA,E.A; SARAIVA,C.C.S.; MACHADO, A.L. Monorestituição de imagens do satélite de alta resolução Ikonos 2 (Geo), utilizando-se da transformação DLT e Modelo Digital de Terreno. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., Belo Horizonte. **Anais XI SBSR**, Belo Horizonte, INPE, 2003, p. 357 – 364.

MOIK, J. G. **Digital processing of remotely sensed images**. Washington DC: Government Printing Office, 1980.

NEIDHART, H.; SESTER, M. Identifying building types and building clusters using 3D-Laser Scanning and GIS data. In: ISPRS CONGRESS, 20. **Proceedings of Comission IV**. Istanbul, Turkey: ISPRS, Jul 2004. p. 115-121.

NEGNEVITSKY, Michael. **Artificial Intelligence, a guide to intelligent systems**. 2. ed. England: Ed. Addison Wesley, 2005.

NOVAK, K. Rectification of digital imagery. **Photogrammetric Engineering and Remote Sensing**, v. 58, n. 3, p. 339-344, 1992.

OHATA, A. T.; QUINTANILHA, J. A. O uso de algoritmos de *clustering* na mensuração da expansão urbana e detecção de alterações na Região Metropolitana de São Paulo (1991-2002). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. **Anais XII Simpósio Brasileiro de Sensoriamento Remoto**. Goiânia, INPE, 2005. p. 647-655.

OLIVEIRA, J. A. **Classificação de regiões usando atributos de forma e seleção de atributos**. 104p. Dissertação (Mestrado em – Curso de Pós-Graduação em Computação Aplicada – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.

OPTECH – **Airborne Laser Terrain Mapper - ALTM 2050 Specifications** – Toronto, Canada, 2002.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de Imagens Digitais: princípios, algoritmos e aplicações**, São Paulo: Ed. Thomson Learning, 2008. pp. 267-278.

PEDRO, P. de C. **Ortorretificação de imagens de alta resolução Ikonos e Quickbird utilizando o modelo APM (Affine Projection Model)**. 97p. Dissertação (Mestrado em Ciências Geodésicas) – Universidade Federal do Paraná, Curitiba, 2005.

POULIOT, D. A., KING, D.J.; BELL, F.W.; PITT D.G. Automated tree crown detection and delineation in high-resolution digital camera imagery of coniferous forest regeneration **Remote Sensing of Environment**. v. 82, n. 2-3, p. 322 – 334, Ed. Elsevier, New York, 2002.

QUINLAN, J. R. **Induction of Decision Trees**. Boston: Kluwer Academic Publishers, 1986. p. 81-106.

QUINLAN, J. R. **C4.5: Programs for Machine Learning**. Sydney: Morgan Kaufmann Publishers, 1993.

RICHARDS, J. A.; JIA, X. **Remote Sensing Digital Image Analysis – An Introduction**. 4. ed. Germany: Ed. Springer, 2006.

ROBINSON, D. J.; REDDING, N. J.; CRISP, D. J. **Implementation of a fast algorithm for segmenting SAR imagery**. Australia: DSTO, Electronics and Surveillance Research Laboratory, DSTO-TR-1242, Jan 2002.

SAFAVIAN, S. R.; LANDGREBE, D. A Survey of Decision Tree Classifier Methodology IEEE Transactions on Systems, Man, and Cybernetics, Vol. 21, No. 3, pp 660-674, May 1991.

SANTOS, A. R. dos; PELUZIO, T. M. O.; SAITO, N. S. **SPRING 5.1.2 - Passo a Passo : aplicações práticas**. Alegre-ES: CAUFES, 2010.

SCHIEWE, J., TUFTE, L. EHLERS, M., Potential and problems of multi-scale segmentation methods in remote sensing. **GeoBIT/GIS** n. 6, p. 34-39, June 2001.

SHAN, Jie; LEE, Scott D. Quality of building extraction from IKONOS imagery. **Journal of Surveying Engineering**, v. 131, n. 1, p. 27-32, Feb. 2005.

SOHN, G; DOWMAN, I. Data fusion of high-resolution satellite imagery and LiDAR data for automatic building extraction. **Journal of Photogrammetric Engineering & Remote Sensing**, v. 62, n. 1, p. 43-63, Feb 2007.

TAO, C. V.; HU, Y.; MERCER, J. B.; SCHNICK, S.; ZHANG, Y. Image rectification using a generic sensor model – Rational Function Model. **International Archives of Photogrammetry and Remote Sensing**, v. XXXIII, Amsterdam, 2000. pp. 874-880

TOUTIN, T. Review article: geometric processing of remote sensing images: models, Algorithms and Methods. **International Journal of Remote Sensing**, v. 25, n. 10, p. 1893 – 1924, May 2004.

WEHR, A. ; LOHR, U. Airborne Laser Scanning – An Introduction and Overview. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 3, pp.68-82, 1999.

WITTEN, I. H.; FRANK, E. **Data Mining : Pratical Machine learning tools and techniques**. San Francisco: Ed. Elsevier, 2005.

XU, R.; WUNSCH II, D. Survey of Clustering Algorithms. **IEEE Transactions on Neural Networks**, v. 16, n. 3, May 2005.

APÊNDICE A – RELATÓRIO DO PROGRAMA DA ORTORRETIFICAÇÃO

**** IMAGEM GEOEYE ***** Resolucao do MDS = 50cm ****

EQUAÇÕES DA TRANSFORMAÇÃO PROJETIVA

$$\begin{aligned} C &= a_{11} * E + a_{12} * N + a_{13} * H + a_{14} \\ L &= a_{21} * E + a_{22} * N + a_{23} * H + a_{24} \\ 0 &= a_{31} * E + a_{32} * N + a_{33} * H + a_{34} \\ w &= a_{41} * E + a_{42} * N + a_{43} * H + a_{44} \end{aligned}$$

| | | | | | | |
|---|---|-----------------|---|---|-----|-----------------------|
| C | | a11 a12 a13 a14 | | E | | a11 a12 a13 a14 |
| L | | a21 a22 a23 a24 | | N | | a21 a22 a23 a24 |
| 0 | = | a31 a32 a33 a34 | * | H | ... | T = a31 a32 a33 a34 |
| w | | a41 a42 a43 a44 | | 1 | | a41 a42 a43 a44 |

$$V1 = T * V2$$

$$T = (V1 * V2') * \text{inv} (V2 * V2')$$

VETOR V2 (Espaço objeto)

| | | | | | | | |
|-----------|------------|--------|------|-----------|------------|--------|------|
| 676933.51 | 7188809.99 | 926.59 | 1.00 | 677319.51 | 7188742.49 | 927.17 | 1.00 |
| 677402.01 | 7188423.99 | 918.51 | 1.00 | 677121.51 | 7188454.49 | 929.74 | 1.00 |
| 676985.01 | 7188529.99 | 927.29 | 1.00 | 677018.01 | 7188627.49 | 927.93 | 1.00 |
| 677198.51 | 7188588.99 | 920.68 | 1.00 | 677320.51 | 7188590.99 | 924.29 | 1.00 |
| 677185.51 | 7188680.49 | 919.55 | 1.00 | 677471.51 | 7188801.49 | 931.89 | 1.00 |
| 677460.51 | 7188650.99 | 925.73 | 1.00 | 677237.51 | 7188780.99 | 925.88 | 1.00 |
| 677092.01 | 7188738.49 | 920.07 | 1.00 | 676941.01 | 7188400.99 | 929.14 | 1.00 |

VETOR V1 (Espaço Imagem)

| | | | | | | | |
|---------|--------|------|------|---------|--------|------|------|
| 55.00 | 66.00 | 0.00 | 1.00 | 829.00 | 201.00 | 0.00 | 1.00 |
| 991.00 | 831.00 | 0.00 | 1.00 | 434.00 | 779.00 | 0.00 | 1.00 |
| 160.00 | 626.00 | 0.00 | 1.00 | 227.00 | 431.00 | 0.00 | 1.00 |
| 584.00 | 502.00 | 0.00 | 1.00 | 830.00 | 501.00 | 0.00 | 1.00 |
| 558.00 | 319.00 | 0.00 | 1.00 | 1133.00 | 88.00 | 0.00 | 1.00 |
| 1109.00 | 382.00 | 0.00 | 1.00 | 663.00 | 123.00 | 0.00 | 1.00 |
| 370.00 | 203.00 | 0.00 | 1.00 | 71.00 | 885.00 | 0.00 | 1.00 |

MATRIZ DE TRANSFORMAÇÃO OU FUNDAMENTAL T

| | | | |
|---------|---------|---------|---------------|
| 2.0003 | -0.0026 | 0.3325 | -1335309.2449 |
| 0.0003 | -1.9983 | 0.8428 | 14364198.6787 |
| 0.0000 | 0.0000 | 0.0000 | 0.0000 |
| -0.0000 | 0.0000 | -0.0000 | 1.0000 |

***** AVALIAÇÃO *****

PCs (PONTOS DE CONTROLE)

| Pontos Lidos (pixels) | | Pontos Calculados (pixels) | | Resíduos (pixels) | |
|-----------------------|----------|----------------------------|----------|-------------------|---------|
| 55.0000 | 66.0000 | 55.5219 | 65.6589 | -0.5219 | 0.3411 |
| 829.0000 | 201.0000 | 827.9956 | 201.1540 | 1.0044 | -0.1540 |
| 991.0000 | 831.0000 | 990.9795 | 830.3280 | 0.0205 | 0.6720 |
| 434.0000 | 779.0000 | 433.5582 | 778.7564 | 0.4418 | 0.2436 |
| 160.0000 | 626.0000 | 159.5080 | 625.7789 | 0.4920 | 0.2211 |
| 227.0000 | 431.0000 | 225.4719 | 431.4983 | 1.5281 | -0.4983 |
| 584.0000 | 502.0000 | 584.2111 | 502.3786 | -0.2111 | -0.3786 |
| 830.0000 | 501.0000 | 829.4385 | 501.4637 | 0.5615 | -0.4637 |
| 558.0000 | 319.0000 | 557.5902 | 318.5809 | 0.4098 | 0.4191 |
| 1133.0000 | 88.0000 | 1133.4494 | 87.2834 | -0.4494 | 0.7166 |

| | | | | | |
|-----------|----------|-----------|----------|---------|---------|
| 1109.0000 | 382.0000 | 1109.7960 | 382.8265 | -0.7960 | -0.8265 |
| 663.0000 | 123.0000 | 663.4432 | 123.1074 | -0.4432 | -0.1074 |
| 370.0000 | 203.0000 | 370.5851 | 203.0901 | -0.5851 | -0.0901 |
| 71.0000 | 885.0000 | 72.4521 | 885.1000 | -1.4521 | -0.1000 |

RMSx = 0.76 pixels = 0.38 metros

RMSy = 0.44 pixels = 0.22 metros

RMS = 0.88 pixels = 0.44 metros

PVs (PONTOS DE VERIFICAÇÃO)

| Pontos Lidos | | Pontos Calculados | | Resíduos | |
|--------------|----------|-------------------|----------|----------|---------|
| 188.0000 | 168.0000 | 188.3078 | 168.6543 | -0.3078 | -0.6543 |
| 633.0000 | 216.0000 | 633.4410 | 214.7193 | -0.4410 | 1.2807 |
| 749.0000 | 376.0000 | 749.5860 | 375.3872 | -0.5860 | 0.6128 |
| 927.0000 | 640.0000 | 926.2040 | 640.7141 | 0.7960 | -0.7141 |
| 498.0000 | 592.0000 | 497.4581 | 591.7361 | 0.5419 | 0.2639 |
| 594.0000 | 731.0000 | 593.1317 | 731.7495 | 0.8683 | -0.7495 |
| 98.0000 | 750.0000 | 98.6517 | 749.7226 | -0.6517 | 0.2774 |
| 390.0000 | 379.0000 | 391.2012 | 378.0062 | -1.2012 | 0.9938 |

RMSx = 0.72 pixels = 0.36 metros

RMSy = 0.76 pixels = 0.38 metros

RMS = 1.05 pixels = 0.53 metros

APÊNDICE B – ÁRVORES DE DECISÃO DOS EXPERIMENTOS 1, 2, 3, 4 E 5

EXPERIMENTO 1-A

(1) B – (2) MDSn – (3) G – (4) R – (5) IRn

```

=== Run information ===
Scheme:      weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:    Amostras_Experimento_1-A
Instances:   260
Attributes:  43
              AREA
              LENGTH
              COMPACT
              CONVEXITY
              SOLIDITY
              ROUNDNESS
              FORMFACTOR
              ELONGATION
              RECT_FIT
              MAINDIR
              MAJAXISLEN
              MINAXISLEN
              NUMHOLES
              HOLESOLRAT
              BANDRATIO
              HUE
              SATURATION
              INTENSITY
              TX_RANGE
              TX_MEAN
              TX_VARIANC
              TX_ENTROPY
              MINBAND_1
              MAXBAND_1
              AVGBAND_1
              STDBAND_1
              MINBAND_2
              MAXBAND_2
              AVGBAND_2
              STDBAND_2
              MINBAND_3
              MAXBAND_3
              AVGBAND_3
              STDBAND_3
              MINBAND_4
              MAXBAND_4
              AVGBAND_4
              STDBAND_4
              MINBAND_5
              MAXBAND_5
              AVGBAND_5
              STDBAND_5
              CLASSE

Test mode:   10-fold cross-validation

=== Classifier model (full training set) ===

J48 pruned tree
-----

AVGBAND_2 <= 208.374258
|  AVGBAND_4 <= 97.126374
|  |  MINBAND_1 <= 0: Fundo (4.0)

```

```

| | MINBAND_1 > 0: Sombra (20.0)
| | AVGBAND_4 > 97.126374
| | BANDRATIO <= 0.610952
| | | MAXBAND_2 <= 908.526611: Pav_Cimentado (32.0)
| | | MAXBAND_2 > 908.526611: Asfalto (6.0)
| | | BANDRATIO > 0.610952: Gramado (23.0)
AVGBAND_2 > 208.374258
| | AVGBAND_2 <= 1052.332423
| | | AVGBAND_4 <= 201.451197
| | | | AVGBAND_4 <= 110.645985
| | | | | LENGTH <= 45.593631: Sombra (6.0)
| | | | | LENGTH > 45.593631: Arvore (2.0)
| | | | AVGBAND_4 > 110.645985
| | | | | AVGBAND_1 <= 260.64486
| | | | | | AVGBAND_4 <= 136.313163
| | | | | | | AREA <= 80.625: Telha_Cer_Escura (2.0)
| | | | | | | AREA > 80.625: Telha_Fibr_Escura (6.0)
| | | | | | AVGBAND_4 > 136.313163: Telha_Cer_Escura (40.0)
| | | | | AVGBAND_1 > 260.64486
| | | | | | AVGBAND_2 <= 791.996119: Telha_Fibr_Escura (18.0/1.0)
| | | | | | AVGBAND_2 > 791.996119: Telha_Fibr_Clara (2.0)
| | | | AVGBAND_4 > 201.451197
| | | | | TX_MEAN <= 322.745903
| | | | | | SOLIDITY <= 0.737983: Telha_Cer_Escura (4.0)
| | | | | | SOLIDITY > 0.737983
| | | | | | | STDBAND_4 <= 36.593832
| | | | | | | | STDBAND_3 <= 31.229783: Telha_Cer_Clara (3.0)
| | | | | | | | STDBAND_3 > 31.229783: Telha_Cer_Escura (6.0)
| | | | | | | | STDBAND_4 > 36.593832: Telha_Cer_Clara (26.0/1.0)
| | | | | TX_MEAN > 322.745903
| | | | | | AVGBAND_5 <= 927.567766: Telha_Fibr_Clara (27.0)
| | | | | | AVGBAND_5 > 927.567766: Telha_Cer_Clara (7.0/1.0)
| | AVGBAND_2 > 1052.332423
| | | TX_ENTROPY <= 0.1902: Arvore (24.0)
| | | TX_ENTROPY > 0.1902: Telha_Fibr_Clara (2.0)

```

Number of Leaves : 20
 Size of the tree : 39
 Time taken to build model: 0.11 seconds

=== Stratified cross-validation ===
 === Summary ===

| | | |
|----------------------------------|-----------|-----------|
| Correctly Classified Instances | 227 | 87.3077 % |
| Incorrectly Classified Instances | 33 | 12.6923 % |
| Kappa statistic | 0.8548 | |
| Mean absolute error | 0.0262 | |
| Root mean squared error | 0.1559 | |
| Relative absolute error | 14.9492 % | |
| Root relative squared error | 52.7021 % | |
| Total Number of Instances | 260 | |

=== Confusion Matrix ===

| | a | b | c | d | e | f | g | h | i | j | <-- classified as |
|----|---|---|----|----|----|----|----|----|----|---|-----------------------|
| 24 | 0 | 0 | 0 | 0 | 1 | 0 | 1 | 0 | 0 | 0 | a = Arvore |
| 0 | 5 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | b = Asfalto |
| 0 | 0 | 4 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | c = Fundo |
| 0 | 0 | 0 | 22 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | d = Gramado |
| 0 | 0 | 0 | 0 | 32 | 0 | 0 | 0 | 0 | 0 | 0 | e = Pav_Cimentado |
| 2 | 0 | 0 | 0 | 0 | 24 | 0 | 0 | 0 | 0 | 0 | f = Sombra |
| 0 | 0 | 0 | 0 | 0 | 0 | 27 | 4 | 1 | 2 | 1 | g = Telha_Cer_Clara |
| 0 | 0 | 0 | 0 | 0 | 0 | 7 | 44 | 1 | 1 | 1 | h = Telha_Cer_Escura |
| 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 28 | 3 | 1 | i = Telha_Fibr_Clara |
| 0 | 0 | 0 | 0 | 1 | 0 | 1 | 2 | 3 | 17 | 1 | j = Telha_Fibr_Escura |

EXPERIMENTO 1-B

(1) B – (2) MDSn – (3) G – (4) R – (5) IRn

=== Run information ===

```

Scheme:      weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:    Amostras_Experimento_1-B
Instances:   260
Attributes:  43
Test mode:   10-fold cross-validation

```

=== Classifier model (full training set) ===

J48 pruned tree

```

AVGBAND_2 <= 208.374258
|  AVGBAND_4 <= 97.126374
|  |  MINBAND_1 <= 0: Fundo (4.0)
|  |  MINBAND_1 > 0: Sombra (20.0)
|  AVGBAND_4 > 97.126374
|  |  BANDRATIO <= 0.610952
|  |  |  MAXBAND_2 <= 908.526611: Pav_Cimentado (32.0)
|  |  |  MAXBAND_2 > 908.526611: Asfalto (6.0)
|  |  BANDRATIO > 0.610952: Gramado (23.0)
AVGBAND_2 > 208.374258
|  AVGBAND_4 <= 110.645985
|  |  BANDRATIO <= 0.719516: Sombra (6.0)
|  |  BANDRATIO > 0.719516: Arvore (25.0)
|  AVGBAND_4 > 110.645985
|  |  TX_MEAN <= 339.053937
|  |  |  AVGBAND_5 <= 555.124582
|  |  |  |  AVGBAND_1 <= 259.677755
|  |  |  |  |  AVGBAND_4 <= 136.313163
|  |  |  |  |  AREA <= 80.625: Telha_Ceramica (2.0)
|  |  |  |  |  AREA > 80.625: Telha_Fibrocimento (6.0)
|  |  |  |  |  AVGBAND_4 > 136.313163: Telha_Ceramica (9.0)
|  |  |  |  |  AVGBAND_1 > 259.677755: Telha_Fibrocimento (17.0)
|  |  |  |  AVGBAND_5 > 555.124582
|  |  |  |  |  TX_RANGE <= 67.847059: Telha_Ceramica (65.0/1.0)
|  |  |  |  |  TX_RANGE > 67.847059
|  |  |  |  |  AVGBAND_5 <= 631.022814: Telha_Fibrocimento (3.0)
|  |  |  |  |  AVGBAND_5 > 631.022814: Telha_Ceramica (8.0/1.0)
|  |  |  TX_MEAN > 339.053937
|  |  |  |  AVGBAND_4 <= 417.750958: Telha_Fibrocimento (29.0)
|  |  |  |  AVGBAND_4 > 417.750958: Telha_Ceramica (5.0)

```

```

Number of Leaves   :     16
Size of the tree   :    31
Time taken to build model: 0.06 seconds

```

=== Stratified cross-validation ===

=== Summary ===

| | | |
|----------------------------------|-----------|-----------|
| Correctly Classified Instances | 219 | 84.2308 % |
| Incorrectly Classified Instances | 41 | 15.7692 % |
| Kappa statistic | 0.8019 | |
| Mean absolute error | 0.0405 | |
| Root mean squared error | 0.1915 | |
| Relative absolute error | 20.2074 % | |
| Root relative squared error | 60.6176 % | |
| Total Number of Instances | 260 | |

```
=== Confusion Matrix ===
```

```

  a  b  c  d  e  f  g  h  <-- classified as
22  0  0  0  0  2  2  0 |  a = Arvore
  0  5  0  1  0  0  0  0 |  b = Asfalto
  0  0  4  0  0  0  0  0 |  c = Fundo
  0  0  0 22  1  0  0  0 |  d = Gramado
  0  0  0  0 32  0  0  0 |  e = Pav_Cimentado
  3  0  0  0  0 20  3  0 |  f = Sombra
  0  0  0  0  0  0 70 17 |  g = Telha_Ceramica
  0  0  0  0  1  0 11 44 |  h = Telha_Fibrocimento

```

EXPERIMENTO 1-C

(1) B – (2) MDSn – (3) G – (4) R – (5) IRn

```
=== Run information ===
```

```

Scheme:      weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:    Amostras_Experimento_1-C
Instances:   260
Attributes:  43
Test mode:   10-fold cross-validation

```

```
=== Classifier model (full training set) ===
```

```
J48 pruned tree
```

```
-----
```

```

AVGBAND_2 <= 208.374258
|  AVGBAND_4 <= 97.126374
|  |  MINBAND_1 <= 0: Fundo (4.0)
|  |  MINBAND_1 > 0: Sombra (20.0)
|  AVGBAND_4 > 97.126374
|  |  BANDRATIO <= 0.610952
|  |  |  MAXBAND_2 <= 908.526611: Pav_Cimentado (32.0)
|  |  |  MAXBAND_2 > 908.526611: Asfalto (6.0)
|  |  BANDRATIO > 0.610952: Gramado (23.0)
AVGBAND_2 > 208.374258
|  AVGBAND_4 <= 110.645985
|  |  BANDRATIO <= 0.719516: Sombra (6.0)
|  |  BANDRATIO > 0.719516: Arvore (25.0)
|  AVGBAND_4 > 110.645985: Edificacao (144.0/1.0)

```

```

Number of Leaves   :      8
Size of the tree   :   15
Time taken to build model: 0.05 seconds

```

```
=== Stratified cross-validation ===
```

```
=== Summary ===
```

| | | |
|----------------------------------|-----------|-----------|
| Correctly Classified Instances | 254 | 97.6923 % |
| Incorrectly Classified Instances | 6 | 2.3077 % |
| Kappa statistic | 0.9648 | |
| Mean absolute error | 0.0073 | |
| Root mean squared error | 0.0807 | |
| Relative absolute error | 3.8694 % | |
| Root relative squared error | 26.3962 % | |
| Total Number of Instances | 260 | |

```
=== Confusion Matrix ===
```

```

  a  b  c  d  e  f  g  <-- classified as
25  0  0  0  0  0  1 |  a = Arvore

```

| | | | | | | | | |
|---|---|---|----|----|----|-----|--|-------------------|
| 0 | 6 | 0 | 0 | 0 | 0 | 0 | | b = Asfalto |
| 0 | 0 | 4 | 0 | 0 | 0 | 0 | | c = Fundo |
| 0 | 0 | 0 | 22 | 1 | 0 | 0 | | d = Gramado |
| 0 | 0 | 0 | 0 | 32 | 0 | 0 | | e = Pav_Cimentado |
| 2 | 0 | 0 | 0 | 0 | 24 | 0 | | f = Sombra |
| 0 | 0 | 0 | 0 | 1 | 1 | 141 | | g = Edificacao |

EXPERIMENTO 2-A

(1) G – (2) MDSn – (3) B – (4) R – (5) IRn

=== Run information ===

```

Scheme:      weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:    Amostras_Experimento_2-A
Instances:   263
Attributes:  43
Test mode:   10-fold cross-validation

```

=== Classifier model (full training set) ===

J48 pruned tree

```

AVGBAND_2 <= 210.131015
|   AVGBAND_3 <= 252.586486
|   |   TX_MEAN <= 263.264416
|   |   |   MINBAND_3 <= 0: Fundo (4.0)
|   |   |   MINBAND_3 > 0: Sombra (20.0/1.0)
|   |   |   TX_MEAN > 263.264416: Gramado (23.0/1.0)
|   |   AVGBAND_3 > 252.586486
|   |   |   MAXBAND_2 <= 908.526611: Pav_Cimentado (30.0)
|   |   |   MAXBAND_2 > 908.526611: Asfalto (5.0)
AVGBAND_2 > 210.131015
|   AVGBAND_4 <= 102.633929
|   |   BANDRATIO <= 0.720846: Sombra (6.0)
|   |   BANDRATIO > 0.720846: Arvore (26.0/1.0)
|   |   AVGBAND_4 > 102.633929
|   |   |   AVGBAND_3 <= 326.552846
|   |   |   |   AVGBAND_4 <= 256.105485
|   |   |   |   |   AVGBAND_3 <= 267.909677
|   |   |   |   |   |   AVGBAND_4 <= 143.754902
|   |   |   |   |   |   |   AREA <= 79.25
|   |   |   |   |   |   |   |   MAINDIR <= 79.916457: Arvore (2.0/1.0)
|   |   |   |   |   |   |   |   MAINDIR > 79.916457: Telha_Cer_Escura (3.0)
|   |   |   |   |   |   |   |   AREA > 79.25: Telha_Fibr_Escura (7.0)
|   |   |   |   |   |   |   |   AVGBAND_4 > 143.754902: Telha_Cer_Escura (43.0/1.0)
|   |   |   |   |   |   |   |   AVGBAND_3 > 267.909677
|   |   |   |   |   |   |   |   |   MINBAND_3 <= 214: Telha_Fibr_Escura (16.0/1.0)
|   |   |   |   |   |   |   |   |   MINBAND_3 > 214: Telha_Fibr_Clara (3.0/1.0)
|   |   |   |   |   |   |   |   |   AVGBAND_4 > 256.105485
|   |   |   |   |   |   |   |   |   |   TX_ENTROPY <= 0.192646
|   |   |   |   |   |   |   |   |   |   |   CONVEXITY <= 1.30039: Telha_Cer_Clara (28.0/1.0)
|   |   |   |   |   |   |   |   |   |   |   CONVEXITY > 1.30039: Telha_Cer_Escura (2.0)
|   |   |   |   |   |   |   |   |   |   |   |   TX_ENTROPY > 0.192646: Telha_Cer_Escura (4.0)
|   |   |   |   |   |   |   |   |   |   |   |   AVGBAND_3 > 326.552846
|   |   |   |   |   |   |   |   |   |   |   |   |   AVGBAND_4 <= 391.686441: Telha_Fibr_Clara (34.0/1.0)
|   |   |   |   |   |   |   |   |   |   |   |   |   |   AVGBAND_4 > 391.686441: Telha_Cer_Clara (7.0/1.0)

```

```

Number of Leaves   :    18
Size of the tree   :   35
Time taken to build model: 0.11 seconds

```

=== Stratified cross-validation ===

=== Summary ===

| | | |
|----------------------------------|-----------|-----------|
| Correctly Classified Instances | 209 | 79.4677 % |
| Incorrectly Classified Instances | 54 | 20.5323 % |
| Kappa statistic | 0.7655 | |
| Mean absolute error | 0.0434 | |
| Root mean squared error | 0.193 | |
| Relative absolute error | 24.7786 % | |
| Root relative squared error | 65.2642 % | |
| Total Number of Instances | 263 | |

=== Confusion Matrix ===

| a | b | c | d | e | f | g | h | i | j | <-- classified as |
|----|---|---|----|----|----|----|----|----|----|-----------------------|
| 22 | 0 | 0 | 0 | 0 | 3 | 0 | 1 | 0 | 0 | a = Arvore |
| 0 | 3 | 1 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | b = Asfalto |
| 0 | 0 | 2 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | c = Fundo |
| 0 | 0 | 0 | 21 | 1 | 1 | 0 | 0 | 0 | 0 | d = Gramado |
| 0 | 2 | 0 | 0 | 28 | 0 | 0 | 0 | 0 | 0 | e = Pav_Cimentado |
| 6 | 0 | 0 | 2 | 0 | 18 | 1 | 0 | 0 | 0 | f = Sombra |
| 0 | 0 | 0 | 0 | 0 | 0 | 28 | 4 | 2 | 1 | g = Telha_Cer_Clara |
| 2 | 0 | 0 | 0 | 0 | 1 | 10 | 38 | 1 | 1 | h = Telha_Cer_Escura |
| 0 | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 30 | 3 | i = Telha_Fibr_Clara |
| 0 | 0 | 0 | 0 | 1 | 0 | 1 | 1 | 1 | 19 | j = Telha_Fibr_Escura |

EXPERIMENTO 2-B

(1) G – (2) MDSn – (3) B – (4) R – (5) IRn

=== Run information ===

Scheme: weka.classifiers.trees.J48 -C 0.25 -M 2
 Relation: Amostras_Experimento_2-B
 Instances: 263
 Attributes: 43
 Test mode: 10-fold cross-validation

=== Classifier model (full training set) ===

J48 pruned tree

```

AVGBAND_2 <= 210.131015
|  AVGBAND_3 <= 252.586486
|  |  TX_MEAN <= 263.264416
|  |  |  MINBAND_3 <= 0: Fundo (4.0)
|  |  |  MINBAND_3 > 0: Sombra (20.0/1.0)
|  |  TX_MEAN > 263.264416: Gramado (23.0/1.0)
|  AVGBAND_3 > 252.586486
|  |  MAXBAND_2 <= 908.526611: Pav_Cimentado (30.0)
|  |  MAXBAND_2 > 908.526611: Asfalto (5.0)
AVGBAND_2 > 210.131015
|  BANDRATIO <= 0.628041
|  |  AVGBAND_4 <= 102.633929: Sombra (4.0)
|  |  AVGBAND_4 > 102.633929
|  |  |  AVGBAND_3 <= 326.552846
|  |  |  |  AVGBAND_5 <= 558.520833
|  |  |  |  |  AVGBAND_3 <= 260.312236
|  |  |  |  |  |  MINBAND_4 <= 57
|  |  |  |  |  |  |  HUE <= 217.127233: Telha_Fibrocimento (5.0)
|  |  |  |  |  |  |  HUE > 217.127233: Telha_Ceramica (4.0/1.0)
|  |  |  |  |  |  |  MINBAND_4 > 57: Telha_Ceramica (11.0)
|  |  |  |  |  |  |  |  AVGBAND_3 > 260.312236: Telha_Fibrocimento (17.0)
|  |  |  |  |  |  |  |  |  AVGBAND_5 > 558.520833: Telha_Ceramica (70.0/2.0)

```

```

| | | AVGBAND_3 > 326.552846
| | | | AVGBAND_4 <= 391.686441: Telha_Fibrocimento (34.0)
| | | | AVGBAND_4 > 391.686441: Telha_Ceramica (7.0/1.0)
| BANDRATIO > 0.628041
| | MAXBAND_5 <= 762: Sombra (3.0)
| | MAXBAND_5 > 762: Arvore (26.0)

```

```

Number of Leaves :      15
Size of the tree : 29
Time taken to build model: 0.07 seconds

```

```

=== Stratified cross-validation ===
=== Summary ===

```

```

Correctly Classified Instances      230           87.4525 %
Incorrectly Classified Instances    33           12.5475 %
Kappa statistic                    0.8416
Mean absolute error                 0.0338
Root mean squared error            0.1702
Relative absolute error             16.9156 %
Root relative squared error        53.9463 %
Total Number of Instances         263

```

```

=== Confusion Matrix ===

```

```

  a  b  c  d  e  f  g  h  <-- classified as
25  0  0  0  0  0  1  0 | a = Arvore
 0  3  0  2  1  0  0  0 | b = Asfalto
 0  0  2  0  0  2  0  0 | c = Fundo
 0  0  0 21  1  1  0  0 | d = Gramado
 0  0  0  0 30  0  0  0 | e = Pav_Cimentado
 1  0  0  2  0 20  2  2 | f = Sombra
 0  0  0  0  0  1 79  8 | g = Telha_Ceramica
 0  0  0  0  1  0  8 50 | h = Telha_Fibrocimento

```

EXPERIMENTO 2-C

(1) G – (2) MDSn – (3) B – (4) R – (5) IRn

```

=== Run information ===

```

```

Scheme:      weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:    Amostras_Experimento_2-C
Instances:   263
Attributes:  43
Test mode:   10-fold cross-validation

```

```

=== Classifier model (full training set) ===

```

```

J48 pruned tree
-----

```

```

AVGBAND_2 <= 210.131015
| AVGBAND_3 <= 252.586486
| | TX_MEAN <= 263.264416
| | | MINBAND_3 <= 0: Fundo (4.0)
| | | MINBAND_3 > 0: Sombra (20.0/1.0)
| | TX_MEAN > 263.264416: Gramado (23.0/1.0)
| AVGBAND_3 > 252.586486
| | MAXBAND_2 <= 908.526611: Pav_Cimentado (30.0)
| | MAXBAND_2 > 908.526611: Asfalto (5.0)
AVGBAND_2 > 210.131015
| BANDRATIO <= 0.628041
| | AVGBAND_4 <= 102.633929: Sombra (4.0)

```

```
| | AVGBAND_4 > 102.633929: Edificacao (148.0/1.0)
| | BANDRATIO > 0.628041
| | MAXBAND_5 <= 762: Sombra (3.0)
| | MAXBAND_5 > 762: Arvore (26.0)
```

```
Number of Leaves :      9
Size of the tree : 17
Time taken to build model: 0.05 seconds
```

```
=== Stratified cross-validation ===
=== Summary ===
```

| | | |
|----------------------------------|-----------|-----------|
| Correctly Classified Instances | 245 | 93.1559 % |
| Incorrectly Classified Instances | 18 | 6.8441 % |
| Kappa statistic | 0.8939 | |
| Mean absolute error | 0.0224 | |
| Root mean squared error | 0.1379 | |
| Relative absolute error | 11.9991 % | |
| Root relative squared error | 45.3926 % | |
| Total Number of Instances | 263 | |

```
=== Confusion Matrix ===
```

| | a | b | c | d | e | f | g | | <-- classified as |
|----|---|---|----|----|----|-----|---|--|-------------------|
| 23 | 0 | 0 | 0 | 0 | 0 | 2 | 1 | | a = Arvore |
| 0 | 3 | 0 | 2 | 1 | 0 | 0 | 0 | | b = Asfalto |
| 0 | 0 | 3 | 0 | 0 | 1 | 0 | 0 | | c = Fundo |
| 0 | 0 | 0 | 21 | 1 | 1 | 0 | 0 | | d = Gramado |
| 0 | 2 | 0 | 0 | 28 | 0 | 0 | 0 | | e = Pav_Cimentado |
| 1 | 0 | 0 | 1 | 0 | 23 | 2 | 2 | | f = Sombra |
| 0 | 0 | 0 | 0 | 1 | 2 | 144 | 1 | | g = Edificacao |

EXPERIMENTO 3-A

(1) R – (2) MDSn – (3) B – (4) G – (5) IRn

```
=== Run information ===
```

```
Scheme:      weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:     Amostras_Experimento_3-A
Instances:    260
Attributes:   43
Test mode:    10-fold cross-validation
```

```
=== Classifier model (full training set) ===
```

```
J48 pruned tree
```

```
-----
```

```
AVGBAND_4 <= 273.720207
| MINBAND_3 <= 0: Fundo (4.0)
| MINBAND_3 > 0
| | AVGBAND_5 <= 572.239761
| | | HUE <= 215.544537: Sombra (27.0)
| | | HUE > 215.544537: Telha_Cer_Escura (2.0)
| | AVGBAND_5 > 572.239761
| | | SOLIDITY <= 0.729557: Sombra (2.0)
| | | SOLIDITY > 0.729557: Arvore (26.0)
AVGBAND_4 > 273.720207
| AVGBAND_2 <= 133.947014
| | BANDRATIO <= 0.621177
| | | MAXBAND_2 <= 904.858398: Pav_Cimentado (29.0)
| | | MAXBAND_2 > 904.858398: Asfalto (6.0)
```



```

| | BANDRATIO > 0.621177: Gramado (22.0)
| AVGBAND_2 > 133.947014
| | AVGBAND_3 <= 326.195122
| | | AVGBAND_5 <= 691.548872
| | | | AVGBAND_3 <= 262.875274
| | | | | TX_MEAN <= 143.832705: Telha_Fibr_Escura (7.0)
| | | | | TX_MEAN > 143.832705: Telha_Cer_Escura (39.0)
| | | | | AVGBAND_3 > 262.875274
| | | | | MINBAND_3 <= 219: Telha_Fibr_Escura (17.0/1.0)
| | | | | MINBAND_3 > 219: Telha_Fibr_Clara (3.0/1.0)
| | | | AVGBAND_5 > 691.548872
| | | | | TX_MEAN <= 289.890978
| | | | | MAXBAND_3 <= 316: Telha_Cer_Clara (3.0)
| | | | | MAXBAND_3 > 316: Telha_Cer_Escura (8.0/1.0)
| | | | | TX_MEAN > 289.890978
| | | | | MINBAND_3 <= 246: Telha_Cer_Clara (23.0)
| | | | | MINBAND_3 > 246: Telha_Cer_Escura (3.0/1.0)
| | | AVGBAND_3 > 326.195122
| | | | TX_MEAN <= 375.099632: Telha_Fibr_Clara (31.0)
| | | | TX_MEAN > 375.099632: Telha_Cer_Clara (8.0)

```

```

Number of Leaves :      18
Size of the tree : 35
Time taken to build model: 0.06 seconds

```

```

=== Stratified cross-validation ===
=== Summary ===

```

| | | | |
|----------------------------------|-----------|----|---|
| Correctly Classified Instances | 221 | 85 | % |
| Incorrectly Classified Instances | 39 | 15 | % |
| Kappa statistic | 0.8287 | | |
| Mean absolute error | 0.0312 | | |
| Root mean squared error | 0.167 | | |
| Relative absolute error | 17.8196 % | | |
| Root relative squared error | 56.4535 % | | |
| Total Number of Instances | 260 | | |

```

=== Confusion Matrix ===

```

```

  a  b  c  d  e  f  g  h  i  j  <-- classified as
22  0  0  0  0  2  0  1  0  2 | a = Arvore
  0  6  0  0  0  0  0  0  0  0 | b = Asfalto
  0  0  4  0  0  0  0  0  0  0 | c = Fundo
  0  0  0 22  0  0  0  0  0  0 | d = Gramado
  0  0  0  0 29  0  0  0  0  0 | e = Pav_Cimentado
  3  0  0  0  0 26  0  0  0  0 | f = Sombra
  0  0  0  0  0  0 27  8  0  0 | g = Telha_Cer_Clara
  1  0  0  0  0  1  6 38  2  3 | h = Telha_Cer_Escura
  0  0  0  0  0  0  1  0 30  3 | i = Telha_Fibr_Clara
  0  0  0  0  0  0  0  2  4 17 | j = Telha_Fibr_Escura

```

EXPERIMENTO 3-B

(1) R – (2) MDSn – (3) B – (4) G – (5) IRn

```

=== Run information ===

```

```

Scheme:      weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:    Amostras_Experimento_3-B
Instances:   260
Attributes:  43
Test mode:   10-fold cross-validation

```

```

=== Classifier model (full training set) ===

```

J48 pruned tree

```

-----
AVGBAND_4 <= 273.720207
|   MINBAND_3 <= 0: Fundo (4.0)
|   MINBAND_3 > 0
|   |   AVGBAND_5 <= 572.239761
|   |   |   HUE <= 215.544537: Sombra (27.0)
|   |   |   HUE > 215.544537: Telha_Ceramica (2.0)
|   |   |   AVGBAND_5 > 572.239761
|   |   |   SOLIDITY <= 0.729557: Sombra (2.0)
|   |   |   SOLIDITY > 0.729557: Arvore (26.0)
AVGBAND_4 > 273.720207
|   AVGBAND_2 <= 133.947014
|   |   BANDRATIO <= 0.621177
|   |   |   MAXBAND_2 <= 904.858398: Pav_Cimentado (29.0)
|   |   |   MAXBAND_2 > 904.858398: Asfalto (6.0)
|   |   |   BANDRATIO > 0.621177: Gramado (22.0)
|   |   AVGBAND_2 > 133.947014
|   |   |   AVGBAND_3 <= 402.222222
|   |   |   |   AVGBAND_5 <= 745.526882
|   |   |   |   |   AVGBAND_3 <= 262.875274
|   |   |   |   |   |   TX_MEAN <= 143.832705: Telha_Fibrocimento (8.0/1.0)
|   |   |   |   |   |   TX_MEAN > 143.832705: Telha_Ceramica (41.0)
|   |   |   |   |   |   AVGBAND_3 > 262.875274: Telha_Fibrocimento (33.0/1.0)
|   |   |   |   |   |   AVGBAND_5 > 745.526882: Telha_Ceramica (42.0)
|   |   |   |   |   |   AVGBAND_3 > 402.222222: Telha_Fibrocimento (18.0)

```

Number of Leaves : 13
 Size of the tree : 25
 Time taken to build model: 0.05 seconds

=== Stratified cross-validation ===
 === Summary ===

| | | |
|----------------------------------|-----------|-----------|
| Correctly Classified Instances | 232 | 89.2308 % |
| Incorrectly Classified Instances | 28 | 10.7692 % |
| Kappa statistic | 0.8656 | |
| Mean absolute error | 0.0286 | |
| Root mean squared error | 0.159 | |
| Relative absolute error | 14.2779 % | |
| Root relative squared error | 50.3068 % | |
| Total Number of Instances | 260 | |

=== Confusion Matrix ===

| a | b | c | d | e | f | g | h | <-- classified as |
|----|---|---|----|----|----|----|----|------------------------|
| 22 | 0 | 0 | 1 | 0 | 3 | 1 | 0 | a = Arvore |
| 0 | 6 | 0 | 0 | 0 | 0 | 0 | 0 | b = Asfalto |
| 0 | 0 | 4 | 0 | 0 | 0 | 0 | 0 | c = Fundo |
| 0 | 0 | 0 | 22 | 0 | 0 | 0 | 0 | d = Gramado |
| 0 | 0 | 0 | 0 | 28 | 1 | 0 | 0 | e = Pav_Cimentado |
| 3 | 0 | 0 | 0 | 0 | 26 | 0 | 0 | f = Sombra |
| 1 | 0 | 0 | 0 | 0 | 2 | 75 | 8 | g = Telha_Ceramica |
| 0 | 0 | 0 | 0 | 1 | 0 | 7 | 49 | h = Telha_Fibrocimento |

EXPERIMENTO 3-C

(1) R – (2) MDSn – (3) B – (4) G – (5) IRn

=== Run information ===

Scheme: weka.classifiers.trees.J48 -C 0.25 -M 2
 Relation: Amostras_Experimento_3-C
 Instances: 260
 Attributes: 43
 Test mode: 10-fold cross-validation

```
=== Classifier model (full training set) ===
```

```
J48 pruned tree
```

```
-----
```

```
AVGBAND_4 <= 273.720207
|  MINBAND_3 <= 0: Fundo (4.0)
|  MINBAND_3 > 0
|  |  AVGBAND_5 <= 572.239761
|  |  |  HUE <= 215.544537: Sombra (27.0)
|  |  |  HUE > 215.544537: Edificacao (2.0)
|  |  |  AVGBAND_5 > 572.239761
|  |  |  SOLIDITY <= 0.729557: Sombra (2.0)
|  |  |  SOLIDITY > 0.729557: Arvore (26.0)
AVGBAND_4 > 273.720207
|  AVGBAND_2 <= 133.947014
|  |  BANDRATIO <= 0.621177
|  |  |  MAXBAND_2 <= 904.858398: Pav_Cimentado (29.0)
|  |  |  MAXBAND_2 > 904.858398: Asfalto (6.0)
|  |  |  BANDRATIO > 0.621177: Gramado (22.0)
|  |  AVGBAND_2 > 133.947014: Edificacao (142.0/1.0)
```

```
Number of Leaves :      9
Size of the tree : 17
Time taken to build model: 0.05 seconds
```

```
=== Stratified cross-validation ===
=== Summary ===
```

| | | |
|----------------------------------|-----------|-----------|
| Correctly Classified Instances | 250 | 96.1538 % |
| Incorrectly Classified Instances | 10 | 3.8462 % |
| Kappa statistic | 0.9412 | |
| Mean absolute error | 0.0122 | |
| Root mean squared error | 0.1039 | |
| Relative absolute error | 6.4951 % | |
| Root relative squared error | 33.9669 % | |
| Total Number of Instances | 260 | |

```
=== Confusion Matrix ===
```

| | a | b | c | d | e | f | g | <-- classified as |
|----|---|---|----|----|----|-----|---|-------------------|
| 24 | 0 | 0 | 0 | 0 | 1 | 2 | 1 | a = Arvore |
| 0 | 6 | 0 | 0 | 0 | 0 | 0 | 0 | b = Asfalto |
| 0 | 0 | 4 | 0 | 0 | 0 | 0 | 0 | c = Fundo |
| 1 | 0 | 0 | 21 | 0 | 0 | 0 | 0 | d = Gramado |
| 0 | 0 | 0 | 0 | 28 | 1 | 0 | 0 | e = Pav_Cimentado |
| 2 | 0 | 0 | 1 | 0 | 26 | 0 | 0 | f = Sombra |
| 0 | 0 | 0 | 0 | 0 | 2 | 141 | 1 | g = Edificacao |

EXPERIMENTO 4-A

(1) IRn – (2) MDSn – (3) B – (4) G – (5) R

```
=== Run information ===
```

```
Scheme:      weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:     Amostras_Experimento_4-A
Instances:    254
Attributes:   43
Test mode:    10-fold cross-validation
```

```
=== Classifier model (full training set) ===
```



```

0 0 0 0 28 0 0 0 0 0 | e = Pav_Cimentado
1 0 1 0 0 24 0 0 0 0 | f = Sombra
0 0 0 0 0 0 28 5 1 1 | g = Telha_Cer_Clara
3 0 0 0 0 2 5 39 0 2 | h = Telha_Cer_Escura
2 0 0 0 0 0 1 2 24 3 | i = Telha_Fibr_Clara
0 0 0 0 0 1 0 1 3 19 | j = Telha_Fibr_Escuro

```

EXPERIMENTO 4-B

(1) IRn – (2) MDSn – (3) B – (4) G – (5) R

=== Run information ===

```

Scheme:      weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:    Amostras_Experimento_4-B
Instances:   254
Attributes:  43
Test mode:   10-fold cross-validation

```

=== Classifier model (full training set) ===

J48 pruned tree

```

AVGBAND_2 <= 205.299251
|  AVGBAND_4 <= 263.24235
|  |  MINBAND_3 <= 0: Fundo (4.0)
|  |  MINBAND_3 > 0: Sombra (20.0)
|  AVGBAND_4 > 263.24235
|  |  BANDRATIO <= 0.617819
|  |  |  MAXBAND_2 <= 933.538818: Pav_Cimentado (28.0)
|  |  |  MAXBAND_2 > 933.538818: Asfalto (6.0)
|  |  BANDRATIO > 0.617819: Gramado (22.0)
AVGBAND_2 > 205.299251
|  AVGBAND_5 <= 109.255917
|  |  MINBAND_1 <= 265: Sombra (6.0)
|  |  MINBAND_1 > 265: Arvore (25.0)
|  AVGBAND_5 > 109.255917
|  |  HUE <= 237.389308
|  |  |  MAXBAND_3 <= 344
|  |  |  |  AVGBAND_2 <= 332.840439: Telha_Fibrocimento (4.0/1.0)
|  |  |  |  AVGBAND_2 > 332.840439: Telha_Ceramica (35.0/1.0)
|  |  |  MAXBAND_3 > 344
|  |  |  |  HUE <= 132.077778: Telha_Ceramica (8.0)
|  |  |  |  HUE > 132.077778
|  |  |  |  |  AVGBAND_3 <= 260.625
|  |  |  |  |  |  MAXBAND_5 <= 314: Telha_Fibrocimento (5.0/1.0)
|  |  |  |  |  |  MAXBAND_5 > 314: Telha_Ceramica (11.0)
|  |  |  |  |  AVGBAND_3 > 260.625
|  |  |  |  |  |  TX_MEAN <= 927.57129: Telha_Fibrocimento (48.0)
|  |  |  |  |  |  TX_MEAN > 927.57129: Telha_Ceramica (2.0)
|  |  HUE > 237.389308: Telha_Ceramica (30.0)

```

```

Number of Leaves :      15
Size of the tree :  29
Time taken to build model: 0.05 seconds

```

=== Stratified cross-validation ===

=== Summary ===

| | | |
|----------------------------------|--------|-----------|
| Correctly Classified Instances | 232 | 91.3386 % |
| Incorrectly Classified Instances | 22 | 8.6614 % |
| Kappa statistic | 0.8912 | |
| Mean absolute error | 0.0228 | |
| Root mean squared error | 0.143 | |

```

Relative absolute error          11.4123 %
Root relative squared error      45.3478 %
Total Number of Instances       254

```

```
=== Confusion Matrix ===
```

```

  a  b  c  d  e  f  g  h  <-- classified as
25  0  0  0  0  0  1  0 | a = Arvore
 0  6  0  0  0  0  0  0 | b = Asfalto
 0  0  4  0  0  0  0  0 | c = Fundo
 0  0  0 22  0  0  0  0 | d = Gramado
 0  0  0  0 28  0  0  0 | e = Pav_Cimentado
 3  0  0  1  0 22  0  0 | f = Sombra
 1  0  0  0  0  0 77  8 | g = Telha_Ceramica
 0  0  0  0  1  0  7 48 | h = Telha_Fibrocimento

```

EXPERIMENTO 4-C

(1) IRn – (2) MDSn – (3) B – (4) G – (5) R

```
=== Run information ===
```

```

Scheme:      weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:    Amostras_Experimento_4-C
Instances:   254
Test mode:   10-fold cross-validation

```

```
=== Classifier model (full training set) ===
```

```
J48 pruned tree
```

```
-----
```

```

AVGBAND_2 <= 205.299251
|  AVGBAND_4 <= 263.24235
|  |  MINBAND_3 <= 0: Fundo (4.0)
|  |  MINBAND_3 > 0: Sombra (20.0)
|  AVGBAND_4 > 263.24235
|  |  BANDRATIO <= 0.617819
|  |  |  MAXBAND_2 <= 933.538818: Pav_Cimentado (28.0)
|  |  |  MAXBAND_2 > 933.538818: Asfalto (6.0)
|  |  BANDRATIO > 0.617819: Gramado (22.0)
AVGBAND_2 > 205.299251
|  AVGBAND_5 <= 109.255917
|  |  MINBAND_1 <= 265: Sombra (6.0)
|  |  MINBAND_1 > 265: Arvore (25.0)
|  AVGBAND_5 > 109.255917: Edificacao (143.0/1.0)

```

```

Number of Leaves :      8
Size of the tree : 15
Time taken to build model: 0.03 seconds

```

```

=== Stratified cross-validation ===
=== Summary ===

```

```

Correctly Classified Instances      246          96.8504 %
Incorrectly Classified Instances      8          3.1496 %
Kappa statistic                     0.9514
Mean absolute error                  0.0097
Root mean squared error              0.0934
Relative absolute error              5.2108 %
Root relative squared error          30.7271 %
Total Number of Instances           254

```

```
=== Confusion Matrix ===
```

| a | b | c | d | e | f | g | <-- classified as |
|----|---|---|----|----|----|-----|-------------------|
| 25 | 0 | 0 | 0 | 0 | 0 | 1 | a = Arvore |
| 0 | 6 | 0 | 0 | 0 | 0 | 0 | b = Asfalto |
| 0 | 0 | 4 | 0 | 0 | 0 | 0 | c = Fundo |
| 0 | 0 | 0 | 21 | 1 | 0 | 0 | d = Gramado |
| 0 | 0 | 0 | 0 | 28 | 0 | 0 | e = Pav_Cimentado |
| 2 | 0 | 0 | 2 | 0 | 22 | 0 | f = Sombra |
| 0 | 0 | 0 | 0 | 1 | 1 | 140 | g = Edificacao |

EXPERIMENTO 5-A

(1) MDSn – (2) B – (3) G – (4) R – (5) IRn

=== Run information ===

```

Scheme:      weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:    Amostras_Experimento_5A
Instances:   265
Attributes:  43
Test mode:   10-fold cross-validation

```

=== Classifier model (full training set) ===

J48 pruned tree

```

-----
AVGBAND_1 <= 234.69207
|  AVGBAND_3 <= 250.338101
|  |  MINBAND_2 <= 0: Fundo (4.0)
|  |  MINBAND_2 > 0: Sombra (19.0)
|  |  AVGBAND_3 > 250.338101
|  |  |  BANDRATIO <= 0.655253
|  |  |  |  MAXBAND_1 <= 553.405762: Pav_Cimentado (29.0)
|  |  |  |  MAXBAND_1 > 553.405762: Asfalto (7.0/1.0)
|  |  |  BANDRATIO > 0.655253: Gramado (22.0)
AVGBAND_1 > 234.69207
|  AVGBAND_1 <= 1058.640447
|  |  BANDRATIO <= 0.489969
|  |  |  AVGBAND_5 <= 831.040541
|  |  |  |  HUE <= 261.186445: Telha_Fibr_Claro (29.0)
|  |  |  |  HUE > 261.186445: Telha_Cer_Escura (2.0)
|  |  |  AVGBAND_5 > 831.040541
|  |  |  |  MAXBAND_4 <= 402: Telha_Fibr_Claro (4.0/1.0)
|  |  |  |  MAXBAND_4 > 402
|  |  |  |  COMPACT <= 0.202906
|  |  |  |  |  AVGBAND_4 <= 358.969849: Telha_Cer_Clara (3.0)
|  |  |  |  |  AVGBAND_4 > 358.969849: Telha_Cer_Escura (2.0)
|  |  |  |  COMPACT > 0.202906: Telha_Cer_Clara (26.0)
|  |  BANDRATIO > 0.489969
|  |  |  AVGBAND_3 <= 247.629717: Sombra (7.0/1.0)
|  |  |  AVGBAND_3 > 247.629717
|  |  |  |  AVGBAND_2 <= 267.343284
|  |  |  |  |  AVGBAND_4 <= 146.820896
|  |  |  |  |  |  AREA <= 82.125: Telha_Cer_Escura (2.0)
|  |  |  |  |  |  AREA > 82.125: Telha_Fibr_Escuro (7.0)
|  |  |  |  |  AVGBAND_4 > 146.820896
|  |  |  |  |  |  AVGBAND_5 <= 699.190154: Telha_Cer_Escura (41.0)
|  |  |  |  |  |  AVGBAND_5 > 699.190154
|  |  |  |  |  |  |  ELONGATION <= 1.752678: Telha_Cer_Escura (2.0)
|  |  |  |  |  |  |  ELONGATION > 1.752678: Telha_Cer_Clara (3.0)
|  |  |  |  AVGBAND_2 > 267.343284
|  |  |  |  |  SATURATION <= 0.172324

```

```

| | | | | | COMPACT <= 0.188201: Telha_Cer_Clara (2.0/1.0)
| | | | | | COMPACT > 0.188201
| | | | | | | MAINDIR <= 144.347338: Telha_Cer_Escura (5.0)
| | | | | | | MAINDIR > 144.347338: Telha_Cer_Clara (2.0)
| | | | | | SATURATION > 0.172324
| | | | | | | STDBAND_1 <= 100.421798: Telha_Fibr_Escuro (17.0)
| | | | | | | STDBAND_1 > 100.421798: Telha_Fibr_Clara (4.0/1.0)
| | AVGBAND_1 > 1058.640447
| | | MAINDIR <= 27.593415: Telha_Fibr_Clara (2.0)
| | | MAINDIR > 27.593415: Arvore (24.0)

```

Number of Leaves : 24

Size of the tree : 47

Time taken to build model: 0.16 seconds

=== Stratified cross-validation ===
 === Summary ===

| | | |
|----------------------------------|-----------|-----------|
| Correctly Classified Instances | 205 | 77.3585 % |
| Incorrectly Classified Instances | 60 | 22.6415 % |
| Kappa statistic | 0.7401 | |
| Mean absolute error | 0.0484 | |
| Root mean squared error | 0.2078 | |
| Relative absolute error | 27.6701 % | |
| Root relative squared error | 70.3239 % | |
| Total Number of Instances | 265 | |

=== Confusion Matrix ===

| | a | b | c | d | e | f | g | h | i | j | <-- classified as |
|----|---|---|----|----|----|----|----|----|----|---|-----------------------|
| 21 | 0 | 0 | 0 | 0 | 1 | 0 | 2 | 1 | 0 | 0 | a = Arvore |
| 0 | 3 | 0 | 0 | 3 | 0 | 0 | 0 | 0 | 0 | 0 | b = Asfalto |
| 0 | 0 | 3 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | c = Fundo |
| 0 | 0 | 0 | 20 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | d = Gramado |
| 0 | 2 | 0 | 2 | 26 | 0 | 0 | 0 | 0 | 0 | 0 | e = Pav_Cimentado |
| 0 | 0 | 0 | 0 | 0 | 24 | 0 | 1 | 0 | 0 | 0 | f = Sombra |
| 0 | 0 | 0 | 0 | 0 | 0 | 21 | 10 | 4 | 1 | 1 | g = Telha_Cer_Clara |
| 1 | 0 | 0 | 0 | 0 | 1 | 7 | 37 | 2 | 6 | 1 | h = Telha_Cer_Escura |
| 2 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 32 | 1 | 1 | i = Telha_Fibr_Clara |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 6 | 2 | 18 | 1 | j = Telha_Fibr_Escuro |

EXPERIMENTO 5-B

(1) MDSn – (2) B – (3) G – (4) R – (5) IRn

=== Run information ===

```

Scheme:      weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:    Amostras_Experimento_5B
Instances:   265
Attributes:  43
Test mode:   10-fold cross-validation

```

=== Classifier model (full training set) ===

J48 pruned tree

```

AVGBAND_1 <= 234.69207
|   AVGBAND_3 <= 250.338101
|   |   MINBAND_2 <= 0: Fundo (4.0)

```



```

| | MINBAND_2 > 0: Sombra (19.0)
| | AVGBAND_3 > 250.338101
| | BANDRATIO <= 0.655253
| | | MAXBAND_1 <= 553.405762: Pav_Cimentado (29.0)
| | | MAXBAND_1 > 553.405762: Asfalto (7.0/1.0)
| | BANDRATIO > 0.655253: Gramado (22.0)
AVGBAND_1 > 234.69207
| | AVGBAND_4 <= 109.030008
| | MINBAND_5 <= 254: Sombra (6.0)
| | MINBAND_5 > 254: Arvore (24.0)
| | AVGBAND_4 > 109.030008
| | HUE <= 221.505632
| | | MAXBAND_2 <= 366
| | | | TX_MEAN <= 336.011971: Telha_Fibrocimento (2.0)
| | | | TX_MEAN > 336.011971: Telha_Ceramica (26.0)
| | | MAXBAND_2 > 366
| | | | AVGBAND_4 <= 392.626087
| | | | AVGBAND_2 <= 259.190045
| | | | | AVGBAND_4 <= 138.408702: Telha_Fibrocimento (7.0/1.0)
| | | | | AVGBAND_4 > 138.408702: Telha_Ceramica (6.0)
| | | | AVGBAND_2 > 259.190045
| | | | | AVGBAND_5 <= 797.660819: Telha_Fibrocimento (44.0)
| | | | | AVGBAND_5 > 797.660819
| | | | | SATURATION <= 0.164882: Telha_Fibrocimento (7.0)
| | | | | SATURATION > 0.164882: Telha_Ceramica (3.0)
| | | | AVGBAND_4 > 392.626087: Telha_Ceramica (5.0)
| | HUE > 221.505632
| | | TX_RANGE <= 23.183603: Telha_Fibrocimento (2.0)
| | | TX_RANGE > 23.183603
| | | MAXBAND_1 <= 452.398682
| | | | HUE <= 229.995186: Telha_Fibrocimento (2.0)
| | | | HUE > 229.995186: Telha_Ceramica (5.0)
| | | MAXBAND_1 > 452.398682: Telha_Ceramica (45.0)

```

Number of Leaves : 19

Size of the tree : 37

Time taken to build model: 0.06 seconds

=== Stratified cross-validation ===
 === Summary ===

| | | |
|----------------------------------|-----------|-----------|
| Correctly Classified Instances | 222 | 83.7736 % |
| Incorrectly Classified Instances | 43 | 16.2264 % |
| Kappa statistic | 0.7941 | |
| Mean absolute error | 0.0424 | |
| Root mean squared error | 0.1968 | |
| Relative absolute error | 21.3969 % | |
| Root relative squared error | 62.6003 % | |
| Total Number of Instances | 265 | |

=== Confusion Matrix ===

| | a | b | c | d | e | f | g | h | <-- classified as |
|----|---|---|----|----|----|----|----|---|------------------------|
| 21 | 0 | 0 | 0 | 0 | 2 | 1 | 1 | 1 | a = Arvore |
| 0 | 3 | 0 | 0 | 3 | 0 | 0 | 0 | 0 | b = Asfalto |
| 0 | 0 | 4 | 0 | 0 | 0 | 0 | 0 | 0 | c = Fundo |
| 0 | 0 | 0 | 22 | 0 | 0 | 0 | 0 | 0 | d = Gramado |
| 0 | 1 | 0 | 1 | 27 | 1 | 0 | 0 | 0 | e = Pav_Cimentado |
| 1 | 0 | 0 | 0 | 0 | 23 | 0 | 1 | 1 | f = Sombra |
| 0 | 0 | 1 | 0 | 0 | 0 | 76 | 13 | 1 | g = Telha_Ceramica |
| 1 | 0 | 0 | 0 | 0 | 0 | 16 | 46 | 1 | h = Telha_Fibrocimento |

EXPERIMENTO 5-C

(1) MDSn – (2) B – (3) G – (4) R – (5) IRn

=== Run information ===

```
Scheme:      weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:    Amostras_Experimento_1C
Instances:   265
Attributes:  43
Test mode:   10-fold cross-validation
```

=== Classifier model (full training set) ===

J48 pruned tree

```
AVGBAND_1 <= 234.69207
|  AVGBAND_3 <= 250.338101
|  |  MINBAND_2 <= 0: Fundo (4.0)
|  |  MINBAND_2 > 0: Sombra (19.0)
|  AVGBAND_3 > 250.338101
|  |  BANDRATIO <= 0.655253
|  |  |  MAXBAND_1 <= 553.405762: Pav_Cimentado (29.0)
|  |  |  MAXBAND_1 > 553.405762: Asfalto (7.0/1.0)
|  |  BANDRATIO > 0.655253: Gramado (22.0)
AVGBAND_1 > 234.69207
|  AVGBAND_4 <= 109.030008
|  |  MINBAND_5 <= 254: Sombra (6.0)
|  |  MINBAND_5 > 254: Arvore (24.0)
|  AVGBAND_4 > 109.030008: Edificacao (154.0/1.0)
```

Number of Leaves : 8

Size of the tree : 15

Time taken to build model: 0.05 seconds

=== Stratified cross-validation ===

=== Summary ===

| | | |
|----------------------------------|-----------|-----------|
| Correctly Classified Instances | 254 | 95.8491 % |
| Incorrectly Classified Instances | 11 | 4.1509 % |
| Kappa statistic | 0.934 | |
| Mean absolute error | 0.0131 | |
| Root mean squared error | 0.1077 | |
| Relative absolute error | 7.2177 % | |
| Root relative squared error | 35.9363 % | |
| Total Number of Instances | 265 | |

=== Confusion Matrix ===

| | a | b | c | d | e | f | g | <-- classified as |
|----|---|---|----|----|----|-----|---|-------------------|
| 23 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | a = Arvore |
| 0 | 4 | 0 | 0 | 2 | 0 | 0 | 0 | b = Asfalto |
| 0 | 0 | 4 | 0 | 0 | 0 | 0 | 0 | c = Fundo |
| 0 | 0 | 0 | 22 | 0 | 0 | 0 | 0 | d = Gramado |
| 0 | 2 | 0 | 1 | 27 | 0 | 0 | 0 | e = Pav_Cimentado |
| 1 | 0 | 0 | 0 | 0 | 23 | 1 | 1 | f = Sombra |
| 0 | 0 | 1 | 0 | 1 | 0 | 151 | 1 | g = Edificacao |